

# PETROTECNIA

Revista del Instituto Argentino del Petróleo y del Gas | ISSN 0031-6598 - AÑO LXV - 1 | 2025

## Inteligencia Artificial en la industria energética



Media sponsor de:



7° Congreso Latinoamericano  
y del Caribe de Refinación ICRP



ICPIS  
5° Congreso Latinoamericano de  
Perforación, Terminación  
e Intervención de Pozos





**A**rancamos 2025 tras un año más de esfuerzo y atravesando muchas dificultades, como la pandemia, el cepo, la inflación, trabas para importar, falta de financiamiento y muchas más. Y es que pese a todo ello, la industria fue capaz de incorporar tecnología e ingeniería de punta, de aumentar la productividad y de bajar costos, con lo que se han superado ampliamente los 700.000 barriles por día de petróleo, y en invierno los 150 millones de m<sup>3</sup> por día de gas.

Pese a las dificultades, hoy estamos exportando nuevamente gas y petróleo. Pero falta. Vaca Muerta, tras 12 años de su primer desarrollo, debería estar produciendo entre 250 y 300 MMm<sup>3</sup>/d de gas y 1 a 1.5 millones de barriles por día de petróleo.

Se está demorando el desarrollo más intensivo de estos recursos en medio de constantes discusiones sobre los efectos del cambio climático y las medidas para mitigarlo. No somos responsables de estas emisiones. De hecho, solo los doce países que queman el 90% del carbón son los responsables de los dos tercios de las emisiones. Y hasta la fecha han hecho poco y nada para solucionarlo. Nuestra región, en cambio, solo emite un 4,5%, la Argentina no llega al 1%. Pero, a diferencia de los países desarrollados, la región tiene un tercio de la población pobre, y la Argentina no está exenta. Y uno de las herramientas de las que dispone el país para combatir esta pobreza es el desarrollo lo antes posible de nuestros recursos naturales. Decimos "lo antes posible" porque si bien la demanda de gas y de petróleo va a durar por muchos años, va a ir siendo reemplazada paulatinamente por otros sistemas, poniendo mucha presión sobre la oferta global de hidrocarburos. Sólo la producción más eficiente y de menor intensidad de emisiones será la que perdure. Y nosotros tenemos grandes recursos y condiciones ideales para el suministro a nivel mundial de gas natural y de petróleo de bajas emisiones.

Ya aparecen nuevamente con fuerza los temas de integración regional gasífera, y también proyectos de exportación vía GNL. Pensemos que podríamos llegar a los 30.000 millones de dólares en exportaciones de gas y petróleo. Nos sobran recursos. Por eso debemos pensar a Vaca Muerta como un proyecto de exportación.

Pero Argentina tiene primero que demostrar que es un proveedor de largo plazo confiable. Contamos con todo lo que es necesario para lograrlo. Una industria totalmente integrada, con una extensa e importante

cadena de valor, altamente competitiva, sustentable y preparada para los desafíos que el futuro nos presenta. Pero todavía

hay muchos temas a resolver. Vaca Muerta puede llegar a admitir una perforación constante de unos 1000 pozos por año, adicionales a la actividad que se desarrolla en otras cuencas y en los campos maduros. Se requerirán inversiones que pueden llegar a valores entre los 20.000 y 30.000 millones de dólares al año.

No solo habrá que perforar pozos, sino que tendremos que atraer fabricantes y compañías de servicios y realizar importantes obras de infraestructura de tratamiento, transporte y exportación de gas y de petróleo. Y para alojar toda esta actividad, los Gobiernos tendrán que ampliar la infraestructura vial y municipal.

Nuestros recursos no son únicos. Se han hecho varios e importantes descubrimientos de gas y petróleo en el mundo con pozos de alta productividad, que pueden llegar a cubrir la demanda a futuro. Y todavía hay mucho más por descubrir. Competimos entonces con muchas oportunidades de inversión a nivel global. Si no ofrecemos condiciones que compitan con ellas, no tendremos un desarrollo intensivo, sostenido y sustentable en el tiempo. Hace falta aún simplificar, homogeneizar y flexibilizar las normativas para facilitar la vida al inversor.

Soplan otros vientos, así que esperemos que finalmente podamos empezar a hablar de realidades y no de nuestro eterno potencial nunca realizado.

Esos y otros desafíos analizaremos y debatiremos este año desde el IAPG, desde las páginas de Petrotecnia y a través de nuestros eventos y congresos. Es el año de la AOG 2025, la cita perfecta para las grandes discusiones. La expo más importante de la región donde esperamos no menos de 20.000 visitantes, entre profesionales y proveedores de la industria, con los últimos avances del sector.

Nos esperan meses intensos con el solo objetivo de llevarles a nuestros profesionales la actualidad de esta industria que no se detiene.

¡Hasta el próximo número!



## Inteligencia Artificial en la industria energética

### Estadísticas

#### 07 Los números del petróleo y del gas

### Tema de tapa

#### 08 Implementación de IA Generativa en la retención y transferencia del conocimiento experto

La inteligencia artificial generativa puede convertirse en una aliada clave para preservar y transferir el conocimiento experto en la industria energética. Este trabajo explora su aplicación concreta en la temática de daño de formación, comparando el desempeño de dos versiones de ChatGPT. El objetivo: potenciar la toma de decisiones técnicas y mejorar la formación de nuevos profesionales.

*Por Simón Marco, Alma Sinojmeri, José Marco Murabito, Marcela Zaira Mucci, Martín Rendichi, María Fernanda Santilli y Gerardo Emanuel Bagnati (Y-TEC).*

#### 14 Analytics aplicado a unidades de reformado de naftas: desarrollo de un modelo predictivo para la desactivación de catalizadores

El reformado catalítico enfrenta desafíos por la desactivación progresiva de catalizadores. Este de-

sarrollo predictivo permite estimar el fin de ciclo y optimizar la planificación operativa con datos en tiempo real.

*Por Alejandro Iriarte, Gustavo Garbati, Tomás Lew, J. Lucas Bali y José Carlucci (YPF).*

#### 20 Inteligencia Artificial en el análisis automático de imágenes aplicado a la inspección de líneas eléctricas aéreas

El uso de inteligencia artificial en el análisis automático de imágenes permite optimizar la inspección de líneas aéreas y estaciones transformadoras, reduciendo fallas, tiempos de respuesta y riesgos operativos.

*Por Martín Alejandro Themtham, Francisco Manuel Colombo, Miguel Moreno (Pan American Energy)*



#### 26 Mejora de la eficiencia operativa en equipos de producción de gas: Detección temprana de eventos de erosión con modelos de Machine Learning (ML)

El uso de modelos de Machine Learning permite anticipar fallas por erosión en equipos clave de producción de gas, mejorando la eficiencia operativa y reduciendo riesgos. Este enfoque reemplaza el monitoreo tradicional con soluciones predictivas basadas en datos. Una innovación clave para garantizar la seguridad y continuidad de las operaciones.

*Por Camila Sabrina Juan Suriano; Jaime Andrés Vega Becerra (Practia), Julio Sandoval; Cristian Grau Viñolo; Ignacio Mason (Tecpetrol).*





### 30 **Aplicación de Inteligencia Artificial para el análisis de facies sedimentarias**

El uso de inteligencia artificial y machine learning permite clasificar facies sedimentarias con mayor precisión, reduciendo la subjetividad del análisis. Esta herramienta acelera el estudio de testigos de roca y mejora la comprensión de los ambientes sedimentarios.

*Por Isabel Eugenia Giannoni, Mariano Germán Arregui, Augusto Nicolas Varela (Y-Tec y CONICET) y Javier Vásquez (YPF).*

### 36 **Predicción de COT a partir de atributos sísmicos, usando algoritmos de Machine Learning en Python**

El uso de machine learning sobre atributos sísmicos permite predecir el contenido orgánico total (COT) con mayor precisión en formaciones como Vaca Muerta. Esta metodología mejora la caracterización de reservorios no convencionales y amplía la cobertura areal de datos geoquímicos.

*Por Alejandro Bascur (Pampa Energía), Enzo Luna (Pampa Energía) y Hernán Merlino (IGPUBA – FIUBA).*

## Notas técnicas

### 42 **Aplicación de tecnología química surfactante para reducir caudal de inyección de Gas Lift en pozos Shale Oil**

Una prueba piloto con espumante en pozos gas lift del yacimiento Médano de la Mora permitió reducir en un 28% el caudal de gas inyectado. La técnica demostró ser viable para pozos no con-



vencionales con bajo contenido de agua. Menor consumo, mismos niveles de producción.

*Por Luciana Masud, María Paz Valderrama (Vista Energy), Joanna Villanova y Jimmy López (PECOM Energía).*

### 48 **Análisis de contenido de video (VCA) o video inteligente en la industria del petróleo y el gas. Seguridad en el trabajo, protección y medio ambiente**



El análisis de contenido de video permite identificar riesgos en tiempo real y optimizar la gestión de seguridad, salud y ambiente en la industria del petróleo y gas. Mediante técnicas de machine learning, detecta eventos críticos, evita falsas alarmas y mejora la toma de decisiones. Una solución inteligente para operaciones más seguras y eficientes.

*Por Julio Shiratori (Consultor de Nuevas Tecnologías en Petróleo y Gas), Fabio David Chiarandini (Asset Manager Consultant), Sebastián Rasilla y Diego Estrella (Arkania Systems).*


## Breves

- 56 **Congresos y jornadas.**  
Los que fueron. Los que vendrán.
- 58 **Noticias de la Industria**
- 63 **Novedades desde Houston**
- 64 **Noticias del IAPG**




# LOS NÚMEROS DEL PETRÓLEO Y DEL GAS


## Producción de petróleo versus importación y exportación




## Producción de gas natural versus importación y exportación




## Ventas de los principales productos




## Precio del petróleo de referencia WTI



## Cantidad de equipos en perforación



## Pozos perforados



# Implementación de IA generativa en la retención y transferencia del conocimiento experto

Por *Simón Marco, Alma Sinojmeri, José Marco Murabito, Marcela Zaira Mucci, Martín Rendichi, María Fernanda Santilli y Gerardo Emanuel Bagnati* (Y-TEC).

*Este trabajo fue seleccionado en las 3<sup>o</sup> Jornadas de Revolución Digital para Petróleo y Gas.*

La inteligencia artificial generativa puede convertirse en una aliada clave para preservar y transferir el conocimiento experto en la industria energética. Este trabajo explora su aplicación concreta en la temática de daño de formación, comparando el desempeño de dos versiones de ChatGPT. El objetivo: potenciar la toma de decisiones técnicas y mejorar la formación de nuevos profesionales.



**E**n este trabajo se ha presentado una comparación entre dos modelos de generación de lenguaje natural basados en ChatGPT (en sus versiones 3.5 Turbo y 4.0), aplicados a la tarea de responder consultas sobre Daño de Formación. El daño de formación es un fenómeno que afecta negativamente a la producción de pozos convencionales y *Tight*. Existen múltiples mecanismos físicos, químicos, térmicos o incluso biológicos que pueden dar origen a un daño de formación e impactar en diferentes magnitudes individualmente, o suceder varios en simultáneo, por lo que suele ser una temática compleja de abordar. Algunos de estos mecanismos ocurren de manera inevitable, pero otros pueden deberse a decisiones de diseño/planificación o errores durante las operaciones de perforación, terminación, *workover* y/o estimulación.

Sin dudas, la ocurrencia de muchas de las pérdidas de producción asociadas a daño de formación está relacionada con la experiencia y el expertise del profesional a cargo de tomar decisiones. El acceso rápido al conocimiento experto potenciará al profesional de menor expertise ayudándolo a prevenir la generación de daños o diseñar tratamientos de mitigación más efectivos. El objetivo principal de este trabajo es crear una herramienta digital que permita principalmente:

- Retener de manera permanente el conocimiento experto y volcarlo en una herramienta digital que facilite el acceso al mismo.
- Acompañar personal de menor expertise en la toma de decisiones.
- Reforzar el modelo de formación activa *On The Job* (Modelo 70-20-10).

Como solución tecnológica se optó por el uso de inteligencia artificial generativa, permitiendo abaratar costos y disminuir tiempos de desarrollo e implementación. Específicamente se trabajó con la arquitectura RAG (Retriever-Augmented Generative) que incluye el modelo de OpenAI y permite la ingesta de información adicional, sin descuidar aspectos relacionados a ciberseguridad, gobierno y legales.

Se han evaluado diferentes aspectos relacionados con la calidad, la fiabilidad, la velocidad y la relevancia de las respuestas generadas por ambos modelos, y los resultados han mostrado que el modelo ChatGPT 4.0 supera al modelo ChatGPT 3.5 Turbo en la mayoría de los aspectos evaluados, excepto en la velocidad de respuesta, donde el modelo más antiguo presenta una mayor fluidez.

## Introducción

El daño de formación es uno de los problemas más significativos que afectan la productividad de los pozos de petróleo y gas, tanto en reservorios convencionales como en *Tight*. Este fenómeno altera las propiedades naturales de la roca circundante al pozo, incluyendo la permeabilidad y la capilaridad, lo que a su vez disminuye la eficiencia del flujo de fluidos desde y hacia el reservorio. Múltiples mecanismos físicos, químicos, térmicos e incluso biológicos pueden desencadenar el daño de formación, actuando de forma individual o combinada según las características específicas del yacimiento, la composición de la roca y los procedimientos operativos implementados.

El diagnóstico, la prevención y la mitigación del daño de formación requieren de un análisis integral y multidisciplinario, que involucre el conocimiento de la geología, la petrofísica, la ingeniería de yacimientos, la ingeniería de producción, la química y la mecánica de rocas. Sin embargo, este análisis muchas veces se ve dificultado por la escasez, la incertidumbre o la inaccesibilidad de los datos necesarios para caracterizar el sistema pozo-reservorio. Además, no existe una metodología estándar o universal para abordar el problema del daño de formación, sino que cada caso debe ser estudiado de forma particular, considerando las condiciones específicas y las hipótesis formuladas. Esto implica que la experiencia y el criterio del profesional a cargo son factores



clave para tomar decisiones acertadas y optimizar la producción de los pozos.

No obstante, el sector petrolero y gasífero enfrenta el desafío de la rotación acelerada del personal, debido al recambio generacional, la migración a otras compañías o la rotación interna a otras áreas. Esto implica la pérdida del conocimiento experto y la dificultad para capacitar y acompañar al personal de menor experiencia. Asimismo, la formación académica en las carreras afines al sector suele ser insuficiente o poco profunda en lo que respecta al daño de formación y la estimulación matricial, lo que genera una brecha entre la teoría y la práctica. Por otro lado, los objetivos orientados a reducción de costos y tiempos, así como otros objetivos que no necesariamente priorizan la producción final del pozo, pueden afectar negativamente la calidad y la cantidad de información generada para el análisis del daño de formación, impactando en la certeza del diagnóstico necesario para la correcta prevención o mitigación del daño.

En este contexto, surge la necesidad de desarrollar una herramienta digital que permita retener y transferir el conocimiento experto sobre el daño de formación, así como asistir y capacitar al personal de menor experiencia en la toma de decisiones. Para ello, se propone el uso de inteligencia artificial generativa (IAG), una rama de la inteligencia artificial que se dedica a generar contenidos de forma automática, imitando el estilo y el lenguaje humano. La IAG puede aprovechar el gran volumen de información disponible en diferentes formatos y fuentes para crear contenidos originales, coherentes y relevantes para una determinada tarea o consulta. La IAG tiene aplicaciones potenciales en diversos campos, como la educación, el periodismo, la publicidad, el entretenimiento o la medicina (Jarrahi et al., 2023) (Dam et al., 2024).

En este trabajo, se utiliza la arquitectura RAG (Singh et al., 2024), que combina el modelo de OpenAI GPT-3.5 Turbo y GPT-4.0 con un mecanismo de recuperación y atención de documentos, para generar respuestas a preguntas relacionadas con el daño de formación. El modelo se entrena con datos provenientes de diversas fuentes, como libros, artículos, informes, presentaciones, manuales, protocolos, etc., que abarcan distintos aspectos del daño de formación y la estimulación matricial. El modelo se implementa en una plataforma web, que permite al usuario interactuar con el sistema mediante un chatbot, que simula una conversación con un experto en la materia. El sistema es capaz de responder a consultas específicas, proporcionar información general, sugerir recomendaciones, mostrar ejemplos, generar tablas comparativas o de resumen, entre otras funcionalidades.

Para garantizar la calidad y fiabilidad del contenido que nutre las respuestas de la IAG, se ha conformado un equipo de expertos en la temática de daño de formación. Este grupo tiene acceso a una base documental o repositorio, donde puede actualizar o eliminar los documentos que no sean pertinentes, actuales o exactos. De esta forma, la herramienta dispone de información validada y revisada por los especialistas, lo que facilita su uso a los usuarios de la plataforma. Con este procedimiento, se pretende reducir las brechas generacionales existentes en los métodos tradicionales de transferencia

de conocimiento, modernizar los medios de acceso a la información y optimizar el tiempo de los profesionales delegando a la IA la búsqueda de respuestas entre miles de documentos.

## Metodología

La solución propuesta se basa en el uso de ChatGPT (GPT-3.5 Turbo y GPT-4.0) de la compañía OpenAI. La elección de este modelo se basó en la rapidez con que se podía desplegar los componentes en la nube, fácil configuración y soporte técnico y funcional. Además, se buscaba transparencia y manejo de una IA responsable. También es importante considerar el tiempo que la industria dispone para desarrollar una Prueba de Concepto y su posterior puesta a disposición de los usuarios. Contar con un modelo entrenado y validado ofrece ventajas (tiempos, costos y menor esfuerzo) sobre otros que necesitan de un “tuning” previo, es decir, personalización y optimización de un LLM para que responda de manera efectiva a las necesidades y expectativas del usuario final.

Se implementó una arquitectura del tipo RAG (detallada anteriormente) que desplegó en la nube los siguientes recursos:

- Repositorio de documentación: almacenamiento privado, que permitió incorporar información curada de la compañía. Este repositorio contiene dos carpetas, en una de ellas se encuentran los documentos que la herramienta permite reproducir y mostrar al pulsar una cita de la respuesta, y en la otra carpeta corresponde a documentos que por confidencialidad o copyright no tiene permitido reproducir. En estos casos, el usuario deberá acceder al documento por sus medios, respetando los permisos de acceso heredados de su perfil en la compañía. Los documentos se almacenan en un primer repositorio y luego pasan a las diferentes carpetas del almacenamiento privado.
- Base de Datos no relacional: almacenamiento, trazabilidad de preguntas y repuestas por usuario, tiempos de respuestas, datos de auditoría y otros de carácter analítico.
- Recursos para el manejo de índices: los documentos almacenados se separan en partes o bloques que luego son indexados y de esta manera fácilmente accesibles por los demás recursos.
- Componente OpenAI: despliegue del modelo dentro de la arquitectura cloud.
- Prompt: instrucciones que permiten configurar estilos y formas de respuestas, así como también bloquear palabras y/o temáticas que contenga la consulta y rechazarla en el chat.
- FrontEnd: para el manejo de la interacción entre usuario y el chat, como historial de últimas conversaciones, posibilidad de calificar respuestas con escala de 5 estrellas, citas con link a cada página de los documentos utilizados para elaborar esa respuesta, panel de visualización de dichos documentos dentro del propio módulo de chat, y preguntas sugeridas para continuar la conversación.

### Retrieval. Argument. Generation. RAG




Figura 1. Circuito que sintetiza la “conversación” que el usuario tiene sobre la información corporativa de la organización.

- Arquitectura Zero Trust: componentes que aseguran un alto nivel de seguridad y aislamiento de la red debido a que se requería un adecuado entorno de producción, donde las estrictas medidas de seguridad son primordiales (Rose et al., 2020). Este modelo de arquitectura asegura que cada solicitud esté autenticada y autorizada, lo que reduce significativamente el riesgo de amenazas internas. Asimismo, garantiza una comunicación segura, aislada y eficiente entre los componentes, siguiendo un modelo de confianza cero y de capa cerrada de redes.

En la Fig. 1, se representa el circuito que se sigue desde el momento que el usuario realiza una consulta, busca en el índice la información correspondiente en el repositorio de información y ese resultado se agrega a la consulta del prompt que fue configurado previamente. Con esa información se llama al servicio de OpenAI que devuelve la respuesta al chat en el FrontEnd.

Cada respuesta provista en el chat puede ser evaluada por los usuarios y calificada en cuanto a su nivel de certeza, duda o precisión. Estas respuestas, en conjunto con sus calificaciones, se almacenan en una base de datos interna para su posterior evaluación por parte de un experto en la materia. A su vez, la trazabilidad posterior en cuanto a la repetición de una consulta es un indicador interno para detectar puntos de debilidad en el “know-how” general y contemplar capacitaciones específicas relacionadas con ese tema.

Debido al manejo sensible de la información y al cumplimiento estricto de las normas establecidas a nivel gobierno corporativo, es que se tuvieron en cuenta los siguientes puntos que se explican a continuación:

- Políticas de uso: se estableció un marco normativo que garantizó el acceso a datos curados, gestión del costo y la calidad de la operación de la información. Fue crucial la definición del uso coherente, integrado y controlado de la información de la organización.
- Marco legal: cada unidad de negocio se responsabilizó por definir, catalogar y asegurar la calidad de datos bajo su dominio, tanto propio como de terceros de acuerdo con las legislaciones vigentes.
- Monitoreo y métricas: Se evaluó el rendimiento de los modelos de LLM mediante métricas objetivas como la precisión, repetitividad, diversidad, ocurrencia de alucinaciones (respuesta confiada que no está justificada por los datos con los que ha sido entrenada) y relevancia de las respuestas generadas, así como métricas subjetivas como la satisfacción y confianza de los usuarios.
- Ataques del tipo inyección: Se evaluaron casos donde se pudieran insertar entradas maliciosas para alterar el comportamiento del modelo, así como también la extracción de información sensible.

## Resultados

En este trabajo se realizó una evaluación comparativa entre dos modelos de generación de lenguaje natural basados en GPT-3: ChatGPT 3.5 Turbo y ChatGPT 4.0. El objetivo fue medir el desempeño de ambos modelos en la tarea de responder preguntas sobre información corporativa de la organización, utilizando como fuente de datos un repositorio de documentos oficiales. Para ello, se consideraron los siguientes aspectos:

- Velocidad de respuesta: el tiempo que tarda el modelo en generar una respuesta a una consulta del usuario.
- Calidad y completitud de la respuesta: el grado de precisión, coherencia, relevancia y exhaustividad de la respuesta generada por el modelo, en relación a la consulta y a la información disponible en los documentos.
- Ocurrencia de alucinaciones: la frecuencia con la que el modelo genera información falsa, inventada o no respaldada por los documentos.
- Confusión de temas: la frecuencia con la que el modelo mezcla o cambia de tema en la respuesta, sin atender a la consulta o al contexto de la conversación.
- Interpretación de la información proveniente de los documentos: la capacidad del modelo para procesar, comprender y extraer información relevante de los documentos.
- Cambios de respuesta ante la repregunta: la consistencia del modelo al responder a la misma consulta.

o a una consulta similar, en diferentes ocasiones o con diferentes formulaciones.

- Preguntas fuera de los temas permitidos: la forma en que el modelo maneja las consultas que no están relacionadas con la información corporativa de la organización, o que violan las políticas de uso o el marco legal establecido.
- Búsqueda de respuestas en tablas: la capacidad del modelo para localizar, interpretar y sintetizar información proveniente de tablas presentes en los documentos.
- Generación de tablas: la capacidad del modelo para crear tablas a partir de la información disponible en los documentos, o a partir de la combinación de diferentes fuentes de datos.
- Reconocimiento y representación de ecuaciones químicas: se refiere a la capacidad del modelo para identificar, reproducir y presentar adecuadamente las ecuaciones químicas contenidas en los textos.
- Manejo de símbolos especiales (como subíndices, superíndices y el alfabeto griego): hace referencia a la habilidad del modelo para identificar, reproducir y presentar de manera correcta los caracteres especiales frecuentemente usados en documentos, en particular dentro de fórmulas químicas y ecuaciones matemáticas.
- Reproducción correcta de ecuaciones matemáticas: describe la capacidad del modelo para detectar, duplicar y mostrar con exactitud las ecuaciones matemáticas incluidas en los documentos.

Los resultados de la evaluación mostraron que ChatGPT 4.0 superó ampliamente a ChatGPT 3.5 Turbo en todos los aspectos, excepto en la velocidad de respuesta. ChatGPT 4.0 demostró una mayor calidad y completitud de las respuestas, una menor ocurrencia de alucinaciones, una mejor interpretación de la información proveniente de los documentos, una mayor consistencia ante la repregunta, una mejor gestión de las preguntas fuera de los temas permitidos, una mayor habilidad para buscar respuestas en tablas y generar tablas, y una mejor reproducción de ecuaciones de reacción química y caracteres especiales. La capacidad de interpretar y reproducir ecuaciones matemáticas sigue siendo un desafío no superado por ambos modelos. Cabe aclarar que esta situación se ha observado en el contexto de modelos aplicados dentro de la arquitectura RAG, operando sobre documentación indexada (mayoritariamente documentos en formato .pdf), lo cual podría variar en cuanto a respuestas generadas en versiones libres que operan fuera de ambientes corporativos.

Un aspecto diferencial de ChatGPT 3.5 Turbo fue su velocidad, lo que generaba una mayor fluidez en la interacción con el usuario, pero a costa de una menor calidad y fiabilidad en las respuestas. Cabe señalar que, en determinados momentos, el modelo ChatGPT 4.0 ha presentado tiempos de espera superiores al minuto, lo cual puede afectar negativamente a la motivación del usuario para continuar el diálogo.

La versión avanzada de ChatGPT 4.0 se destaca por

ser un modelo más desarrollado y complejo, reflejado en las optimizaciones en la arquitectura, el incremento en su tamaño, las mejoras metodológicas durante el entrenamiento, la calidad del conjunto de datos utilizado y el refinamiento posterior. Estas mejoras le permiten al modelo captar mejor las relaciones semánticas y sintácticas entre las palabras, las frases y los párrafos, así como generar textos más naturales, fluidos y coherentes. Además, ChatGPT 4.0 tiene una mayor capacidad para manejar información estructurada, como tablas y fórmulas, y para adaptarse al dominio y al contexto de la conversación.

Algunos de los aspectos evaluados se pudieron solucionar o mejorar con modificaciones en el prompt, es decir, en la forma en que se formula la consulta al modelo. Por ejemplo, la velocidad de respuesta se puede aumentar levemente limitando el número de tokens o palabras que el modelo puede generar, o indicando al modelo que termine la respuesta cuando encuentre un punto final. La calidad y completitud de la respuesta se puede mejorar proporcionando al modelo más información sobre el contexto, el propósito y el formato de la respuesta esperada, o utilizando palabras clave o frases específicas que orienten al modelo hacia la información relevante. Los cambios de respuesta ante la repregunta se pudieron minimizar utilizando un prompt que sea consistente y claro, o que le pida al modelo que confirme o corrija su respuesta anterior. Las preguntas fuera de los temas permitidos se pueden manejar incorporando en el prompt una lista de temas permitidos y no permitidos, indicándole al modelo que no puede responder a ese tipo de consultas, o redirigiendo al usuario a otro canal de atención.

Otros aspectos evaluados requieren de mejoras más profundas en el modelo, que no se pueden solucionar solo con modificaciones en el prompt. Por ejemplo, la interpretación de la información proveniente de los documentos se puede mejorar con un mayor preprocesamiento y normalización de los datos, o con una mayor integración entre el modelo de generación de lenguaje natural y el modelo de comprensión de documentos. Otro ejemplo son las dificultades que se a veces presentan en la búsqueda e interpretación de contenido tabulado. Los documentos que se utilizan como fuente de información están indexados y divididos en partes más pequeñas, llamadas chunks, que facilitan su procesamiento por parte del modelo. Sin embargo, esta fragmentación puede provocar que algunas tablas se corten entre dos o más chunks, lo que impide al modelo acceder a toda la información que contiene la tabla y, por lo tanto, afecta la precisión y la completitud de la respuesta.

Los avances en la interpretación y representación de ecuaciones químicas, caracteres especiales (como subíndices, superíndices y el alfabeto griego) y ecuaciones matemáticas forman parte del desarrollo continuo y evolutivo del modelo. Según nuestra experiencia, ChatGPT 3.5 gestionó adecuadamente los subíndices y superíndices; ChatGPT 4.0 avanzó incluyendo la capacidad de manejar ecuaciones químicas y el alfabeto griego; y ninguno de ellos pudo procesar ecuaciones matemáticas

con eficacia, aunque modelos más recientes y perfeccionados están empezando a tener esta capacidad.

En cuanto al motivo de la presencia de alucinaciones en los modelos que se utilizaron, no existe un consenso definido al respecto ya que las redes neuronales que se utilizan tienen procesos en los que podemos saber su entrada y salida, pero poco se publica en forma específica sobre su funcionamiento interno. Algunos investigadores expresan que el origen de las alucinaciones se produce por material inexacto que se encuentra en el conjunto de datos con el que fueron entrenados o bien por las inferencias que hacen los modelos de situaciones específicas que no se encuentran en su material de entrenamiento. Con lo cual, cuando el chat alucina es porque está buscando información o análisis que no está presente en el texto de datos con el que lo han alimentado y que para rellenar los “espacios en blanco” lo hace con palabras que suenen bien, aunque resulten inexactas (Zhang et al., 2023) (Rawte et al., 2023). Por esta razón, el modelo ChatGPT 4.0 presenta una menor ocurrencia de alucinaciones y mejor performance en los demás aspectos detallados que el modelo ChatGPT 3.5 Turbo, ya que se trata de un modelo mejorado, con un nivel de entrenamiento superior y se ha utilizado un conjunto de datos más amplio y diverso (Koubaa, 2023).

Estos resultados demuestran la buena implementación y despliegue de ambos modelos dentro de la herramienta, que actualmente se encuentra en fase de testeo con una célula de usuarios (n 30), donde se está evaluando el grado de satisfacción, la ocurrencia de errores y alucinaciones en las respuestas, dificultades de acceso a la herramienta, aspectos relacionados con la UX y el FrontEnd y otras métricas. Mientras siga activa la fase de testeo, la herramienta cuenta con un switch que permite a los usuarios elegir qué modelo usar (ChatGPT 3.5 Turbo o ChatGPT 4.0) y comparar las respuestas.

Este testeo nos permitirá recoger más feedback y mejorar aún más el rendimiento y la calidad de los modelos, así como detectar posibles áreas de mejora en la herramienta y en la experiencia de usuario. Por ahora, el testeo muestra un alto grado de satisfacción general.

## Conclusiones

En este trabajo se ha presentado una comparación entre dos modelos de generación de lenguaje natural basados en ChatGPT, aplicados a la tarea de responder consultas sobre información corporativa de una organización. Se han evaluado diferentes aspectos relacionados con la calidad, la fiabilidad, la velocidad y la relevancia de las respuestas generadas por ambos modelos, utilizando como fuente de información un conjunto de documentos indexados por una plataforma basada en Retriever-Augmented Generative (RAG). Los resultados han mostrado que el modelo ChatGPT 4.0 supera al modelo ChatGPT 3.5 Turbo en la mayoría de los aspectos evaluados, excepto en la velocidad de respuesta, donde el modelo más antiguo presenta una mayor fluidez.

Estos resultados demuestran el potencial de la inte-

ligencia artificial generativa para facilitar la retención y la transferencia del conocimiento experto dentro de una organización, así como para mejorar la experiencia y la satisfacción de los usuarios que requieren acceder a esa información. Uno de los beneficios clave de integrar ChatGPT con una plataforma basada en RAG es que evita la necesidad de desarrollar y entrenar un modelo propio, un proceso que sería intensivo en recursos humanos, tiempo de procesamiento y costos computacionales considerables. Además, al utilizar RAG, se puede generar respuestas más detalladas y pertinentes que con métodos de generación tradicionales, ya que el modelo puede aprovechar el contenido de los documentos para construir sus respuestas. Sin embargo, el uso de RAG también implica algunos desafíos, como la necesidad de contar con un repositorio de datos bien curado y supervisado para agregar información nueva, además de los costes asociados con el mantenimiento de dicha infraestructura y los tiempos de respuesta incrementados

## Agradecimientos

Los autores queremos expresar nuestro agradecimiento a Y-TEC por brindarnos la oportunidad de innovar en esta disciplina, así como a los equipos de Upstream, Tecnologías Digitales, Legales, Compliance y otros de YPF por el apoyo y la confianza que nos han otorgado y por permitirnos publicar este trabajo. También agradecemos a Microsoft y Pi Consulting por sus valiosas colaboraciones y orientaciones durante el desarrollo de este proyecto.

## Referencias

- Dam S. K., Hong C. S., Qiao Y., Zhang C. (2024). arXiv:2406.16937v1 [cs.CL] - “A Complete Survey on LLM-based AI Chatbots”
- Jarrahi M. H., Askay D., Eshraghi A., Simth P. (2023). Business Horizon Journal 66, pag 87-99 - “Artificial intelligence and knowledge management: A partnership between human and AI”
- Koubaa A. (2023). Preprints 2023030422 - “GPT-4 vs. GPT-3.5: A Concise Showdown”
- Rawte V., Sheth A., Das A. (2023) arXiv:2309.05922v1 [cs.AI] - “A Survey of Hallucination in “Large” Foundation Models”
- Rose S., Borchert O., Mitchell S., Connelly S. (2020). NIST Special Publication 800-207 - “Zero Trust Architecture”
- Singh K. P., Kumar P. (2024). IJETA Journal ISSN:2393-9516 - “BIRAG: Basic Introduction to Retrieval Augmented Generation”
- Zhang Y., Li Y., Cui L., Cai D., Liu L., Fu T., Huang X., Zhao E., Zhang Y., Chen Y., Wang L., Lu A. T. Bi W. Shi F., Shi S. (2023) arXiv:2309.01219v2 [cs.CL] - “Siren’s song in the AI ocean: a survey on hallucination in large language models”



# Analytics aplicado a unidades de reformado de naftas: desarrollo de un modelo predictivo para la desactivación de catalizadores

Por **Alejandro Iriarte, Gustavo Garbati, Tomás Lew, J. Lucas Bali y José Carlucci** (YPF).

*Este trabajo fue seleccionado en las 3<sup>o</sup> Jornadas de Revolución Digital para Petróleo y Gas.*

El reformado catalítico enfrenta desafíos por la desactivación progresiva de catalizadores. Este desarrollo predictivo permite estimar el fin de ciclo y optimizar la planificación operativa con datos en tiempo real.

Las refinerías de petróleo dependen de unidades de proceso que emplean catalizadores para optimizar sus operaciones. Sin embargo, estos catalizadores se desactivan con el paso del tiempo, principalmente por la formación de coque derivado de reacciones de craqueo no deseadas. En el caso de las unidades de reformado semi-regenerativo de nafta (SRCRP<sup>1</sup>), este fenómeno resulta en un aumento de la temperatura de entrada a los reactores para alcanzar la especificación deseada. Una vez que se alcanza un límite de temperatura, se hace necesario implementar un proceso de regeneración para recuperar la actividad del catalizador o reemplazarlo.

La desactivación del catalizador en unidades SRCRP impacta negativamente en la eficiencia y los costos operativos. La comprensión de los mecanismos de desactivación y la implementación de estrategias efectivas de mitigación son esenciales para mantener el óptimo funcionamiento y garantizar la producción eficiente de productos de alto octanaje.

La estimación precisa del momento en que se alcanza el fin de ciclo del catalizador es crucial para optimizar su vida útil y mejorar la planificación de paros en unidades de SRCRP. Para lograr este objetivo, se desarrolló una herramienta que realiza diariamente de forma automática el cálculo y seguimiento de la variable de decisión (denominada Delta WAIT<sup>2</sup>), y predice la carga acumulada por kilo de catalizador a la que se alcanzará el final del ciclo mediante un modelo analítico basado en datos.

El algoritmo de la herramienta se alimenta de datos tomados directamente del historizador de la planta y sus resultados se encuentran disponibles en línea a través de un tablero para los usuarios. Su utilización constituye una mejora respecto a la metodología empleada por los ingenieros de procesos, ya que permite contar con una mejor estimación en etapas tempranas del ciclo.

La predicción se realiza empleando únicamente datos del ciclo actual y se reajusta automáticamente en función del monitoreo del error. Adicionalmente, permite a los usuarios ajustar la predicción a través del input de variables operativas críticas que impactan en la desactivación del catalizador, combinando el modelo de regresión con las especificaciones propias del fabricante. Esto permite la construcción de escenarios, a fin de evaluar distintas simulaciones ante diferentes casos de uso de la unidad.

## Planteo del problema

Las unidades de reformado semi-regenerativo de nafta (SRCRP) procesan principalmente nafta pesada proveniente de la unidad de destilación primaria, sometiéndola a un proceso por el cual moléculas de bajo número de octano (RON<sup>3</sup>) son transformadas en moléculas de alto octanaje. La reacción química tiene lugar en reactores, los cuales están rellenos con catalizador. La función de este material es activar la reacción química y que esta sea selectiva a los productos deseados.

El catalizador pierde paulatinamente su actividad, debido principalmente al depósito de coque sobre su su-

perficie, que se genera como producto de reacciones de cracking indeseadas. Esto impide el contacto del material catalítico con las moléculas presentes en la corriente de nafta pesada. Este fenómeno obliga a aumentar la severidad del proceso, lo cual se traduce principalmente en un incremento en la temperatura de ingreso de la nafta a los reactores, con el objetivo de compensar la pérdida de actividad del catalizador y lograr la especificación deseada.

El incremento en la temperatura ocasionará que el catalizador se desactive con mayor velocidad, ya dicha condición favorece la ocurrencia de reacciones de cracking, y por ende la generación de coque. Eventualmente, el catalizador alcanzará un nivel de desactivación tal que resultará inviable continuar aumentando la severidad para alcanzar la especificación, por lo que se deberá llevar a cabo un proceso de regeneración del catalizador, con el objetivo de recuperar su actividad. Este consiste en someterlo a elevadas temperaturas para quemar el carbón depositado en la superficie, para lo cual se deberá sacar de servicio la unidad durante varios días, generando lucro cesante.

El parámetro que se utiliza para realizar el seguimiento de la desactivación del catalizador se denomina Delta WAIT y se calcula como:

$$\text{Delta WAIT} = \text{WAIT actual} - \text{WAIT teórico}$$

donde:

- WAIT actual: promedio de la temperatura de entrada a los reactores (ponderado por la masa de catalizador).
- WAIT teórico: temperatura requerida a la entrada de los reactores para el catalizador virgen. Se calcula a partir de parámetros operativos y de calidad de la carga, según fórmulas de cálculo dadas por el fabricante.

El Delta WAIT es, por lo tanto, una medida de cuánto se ha incrementado la severidad del proceso respecto de la condición inicial (catalizador virgen) y del grado de desactivación del catalizador.

Cuando se alcanza un valor de Delta WAIT de 35°C, se considera que se ha alcanzado el límite de desactivación y se deberá regenerar el catalizador. Este no puede ser regenerado de forma indefinida, por lo que tras una determinada cantidad de ciclos, se deberá reemplazar en su totalidad.

Poder estimar, con la mayor precisión posible, cuándo se alcanzará el valor de Delta WAIT de 35°C permite aprovechar mejor la vida útil del catalizador y planificar adecuadamente los paros de planta de la Unidad. La metodología que se emplea típicamente para llevar a cabo el monitoreo de este parámetro consiste en realizar una proyección lineal empleando los datos más recientes, lo cual solo resulta conveniente cuando el catalizador se encuentra próximo a la condición de desactivación total, ya que solamente en dicha situación la tendencia típica de la curva se suele aproximar más a un comportamiento lineal; cuando se está promediando el ciclo, las curvas de seguimiento del Delta WAIT muestran un comportamiento no lineal.

La figura 1 ejemplifica el seguimiento del Delta WAIT para varios ciclos operativos históricos.

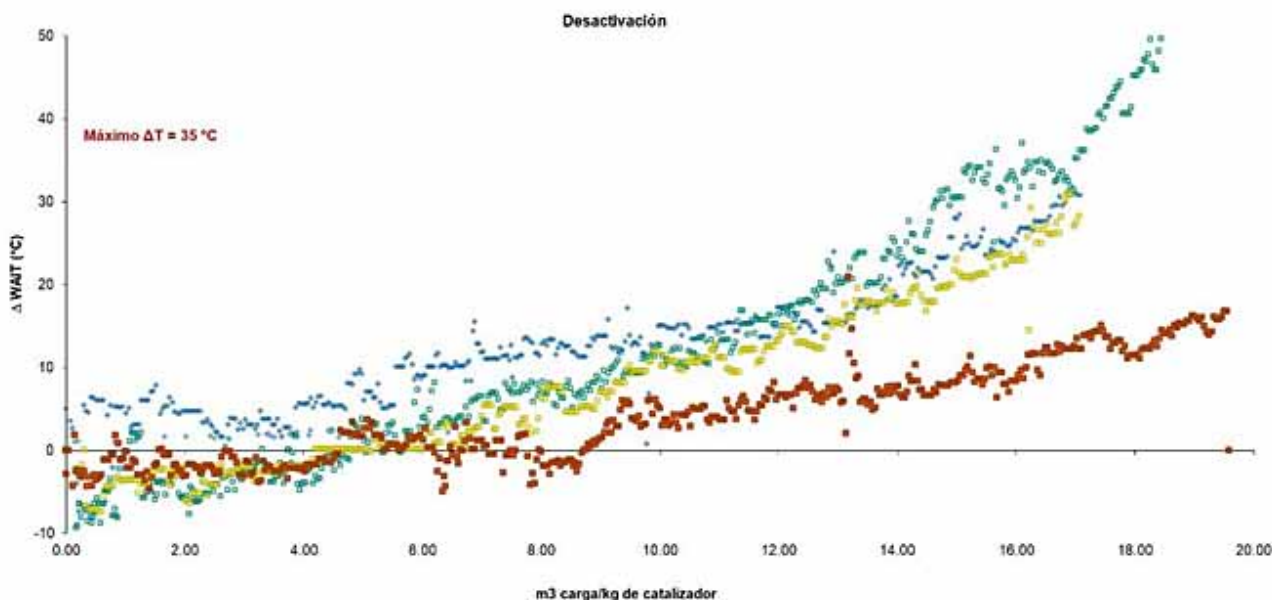


Figura 1. Evolución del Delta WAIT para varios ciclos operativos de catalizador de reformado.

## Desarrollo técnico del trabajo

Se propuso desarrollar una herramienta de monitoreo del Delta WAIT capaz de predecir cuándo se alcanzará la condición de fin de ciclo en función de datos históricos tomados del historizador de la planta, que esté disponible en línea para los usuarios y que se actualice automáticamente en forma diaria.

Durante la etapa inicial del proyecto, se evaluó la posibilidad de emplear modelos avanzados de machine learning, tales como: algoritmos basados en series temporales (ARIMA, Prophet) y algoritmos de regresión basados en árboles de decisión (XGBoost y LightGBM). El objetivo en esta instancia fue desarrollar un modelo capaz de llevar a cabo la predicción del Delta WAIT, entrenado previamente con datos operativos y de calidad obtenidos de varios ciclos anteriores. Estas opciones se descartaron, puesto que se encontraron las siguientes limitaciones:

- No resulta viable utilizar como variables predictoras algunos parámetros operativos y de calidad que afectan a la desactivación del catalizador (ej.: RON, presión del reactor o análisis PIONA<sup>4)</sup>) debido a que no resulta factible conocerlos con la suficiente antelación.
- El impacto de las variables mencionadas anteriormente sobre el Delta WAIT resulta despreciable para los algoritmos de regresión frente al de la carga acumulada por kilogramo de catalizador. Esto fue verificado mediante estudios de importancia de variables, empleando la metodología Boruta.

Las conclusiones anteriores dictaron que solo tendría sentido utilizar la carga acumulada como variable predictora y datos del ciclo en curso para realizar la predic-

ción. Se propuso entonces la utilización de un modelo de ajuste de curvas mediante modelos de regresión tradicionales; luego de realizar pruebas con distintos tipos de funciones, se concluyó que el ajuste exponencial es la que logra una mejor performance, utilizando el RMSE (root mean squared error) como métrica. Debido a la presencia de datos atípicos, fue preciso limpiar la señal de temperatura con un filtro de Hampel de medianas.

El modelo queda entonces definido como una regresión exponencial con la siguiente forma, con  $a$  y  $b$  como parámetros de ajuste y la carga acumulada por kilogramo de catalizador como única variable independiente:

$$\Delta T_{WAIT} = a * e^{b \cdot Carga_{acum} / kgcat}$$

Los cálculos de carga acumulada y Delta WAIT se llevan a cabo diariamente, con lo cual sería viable ajustar la

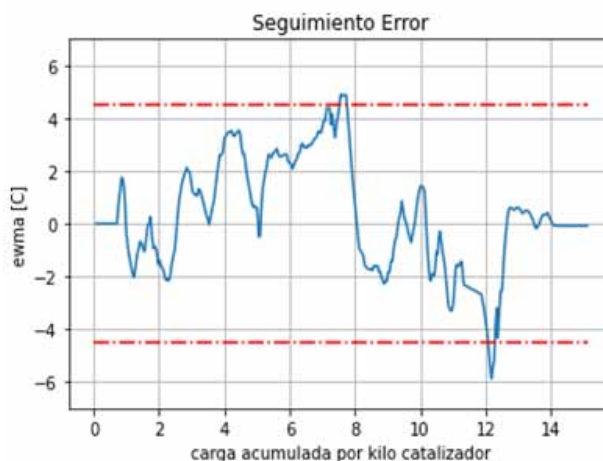


Figura 1. Monitoreo del error (EWMA) según ASTM D6299.




Figura 3. Secuencia de reajuste de la proyección conforme avanza el ciclo operativo del catalizador.

predicción todos los días. Sin embargo, esta metodología generaría una nueva curva de predicción por cada dato real ingresado, y esta no siempre tendría una variación significativa respecto a la anterior.

Por dicho motivo, a los fines prácticos, se propuso llevar a cabo un monitoreo de la performance del modelo a través del error entre los datos reales del ciclo y la última proyección realizada por el modelo. El criterio adoptado consistió en llevar a cabo un reajuste de la curva exponencial únicamente si se ha sobrepasado un determinado valor umbral del error.

Para el seguimiento del error, primero se verifica que no sea un valor atípico (outlier) y luego se utiliza una carta de control del tipo EWMA5, según norma ASTM D6299. El sistema (proyección del Delta WAIT) se considera “fuera de control” si los valores EWMA superan los límites más de 5 veces seguidas. Cuando esto ocurre, se procede a reentrenar el modelo automáticamente (obtener nuevos parámetros a y b de la función exponencial empleando los datos reales del ciclo con los que se cuenta hasta ese momento).

La herramienta fue desarrollada en Python y programada para ejecutarse diariamente. El flujo de trabajo es el siguiente:

1. Conexión al historizador de la planta y lectura de datos de proceso y de calidad correspondientes al día anterior.
2. Cálculo de WAIT actual y WAIT teórico a partir de

los datos obtenidos del historizador.

3. Actualización de carga acumulada y cálculo de Delta WAIT.
4. Aplicación de Filtro de Hampel para limpieza de datos atípicos.
5. Cálculo EWMA y reajuste de la curva de proyección de Delta WAIT, en caso de corresponder.
6. Escritura de resultados en tablas disponibles en un data warehouse, a las cuales se conecta un tablero para visualización por parte de los usuarios.

## Resultados obtenidos

La herramienta desarrollada lleva a cabo la predicción del Delta WAIT hasta el valor de carga acumulada al cual se sobrepasa el límite de 35°C impuesto por la desactivación del catalizador. La Figura 3 ilustra su funcionamiento en distintas etapas de un mismo ciclo de catalizador: al inicio solo se lleva a cabo el monitoreo del Delta WAIT, puesto que el comportamiento del sistema aún no se encuentra en régimen, y por lo tanto no se cuenta con datos suficientes para realizar una proyección en forma adecuada. Cuando se alcanza un determinado valor de carga acumulada, se efectúa la primera proyección, la cual es luego reajustada según la metodología de monitoreo del error mencionada anteriormente.




Figura 4. Ejemplos de aplicación a ciclos históricos.



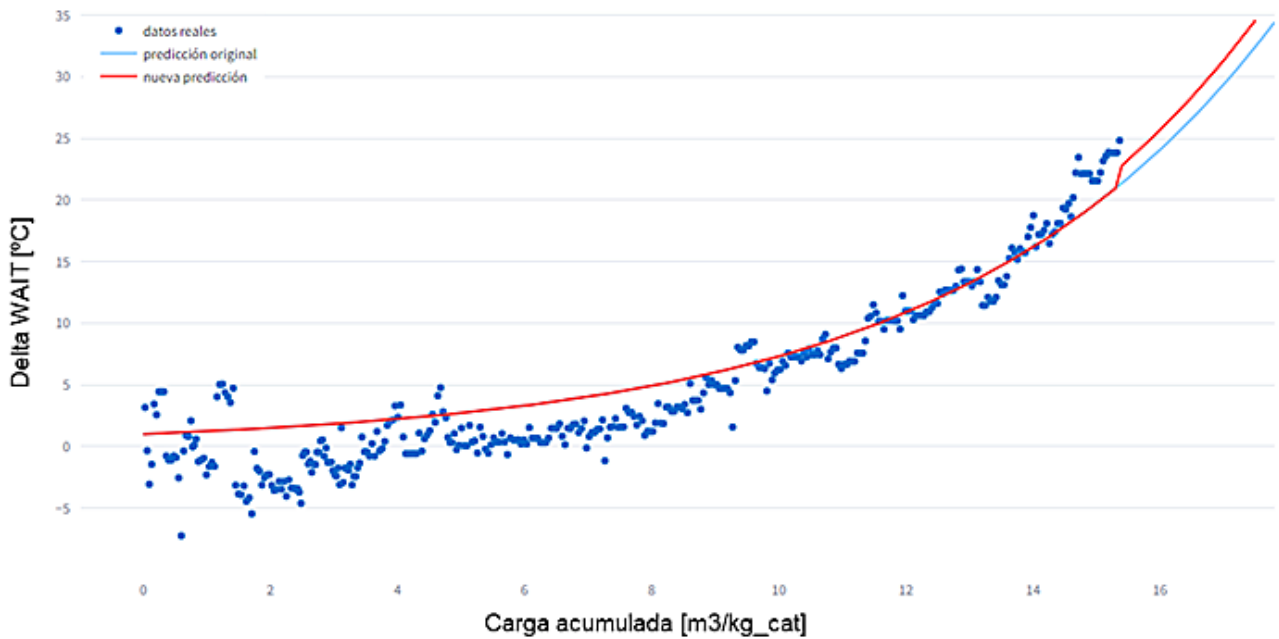


Figura 5. Complemento para evaluación de escenarios.

El modelo fue testeado empleando datos históricos correspondientes a siete ciclos anteriores. Los resultados para tres de ellos pueden visualizarse en las Figuras 3 y 4. Allí, las series de puntos graficadas en color rojo corresponden a los datos históricos utilizados para realizar la proyección, mientras que la serie en color verde corresponde a datos históricos no utilizados para entrenar el modelo, pero sí para evaluar su performance.

Se seleccionó el RMSE como métrica para evaluar la performance del método, obteniéndose una media de 2,5°C entre todos los ciclos históricos evaluados.

Como complemento, se desarrolló también un módulo para evaluación de escenarios, que permite ajustar la proyección original entregada por algoritmo en función de inputs proporcionados por los usuarios. El fundamento de este método consiste en afectar la proyección del Delta WAIT por un factor de corrección ( $v_{des}$ ):

$$\text{Delta WAIT} = a \cdot e^{b \cdot \text{Cargaacum/kgcat}} \cdot v_{des}$$

El cálculo del factor de corrección se realiza en función de datos experimentales proporcionados por el fabricante para evaluar el impacto de determinados parámetros sobre la desactivación del catalizador, tales como el RON, la presión de operación o la relación de reciclo de  $H_2$ .

La figura 5 muestra el ajuste de la proyección que resulta de modificar el RON en 0,5 puntos respecto a la tendencia del ciclo. Este módulo se encuentra en evaluación por parte de los usuarios.

## Conclusiones

Se desarrolló en Python una herramienta que permite estimar la carga acumulada por kilogramo de catalizador a la cual se alcanzará la condición de desactivación del catalizador en unidades de reformado de naftas.

El algoritmo implementado se basó en un modelo de regresión de una función exponencial. Los resultados obtenidos al testear el modelo con datos de ciclos anteriores de desactivación del catalizador fueron evaluados empleando el RMSE como métrica y resultaron satisfactorios.

La herramienta fue puesta a disposición en línea y contribuye a que los usuarios (ingenieros de procesos y de producción) puedan planificar mejor los paros de la unidad y optimizar la vida útil del catalizador.

- 1 Semi-regenerative catalytic reformer process
- 2 Weight Average Inlet Temperature
- 3 Research Octane Number
- 4 Parafinas, isoparafinas, olefinas, nafténicos y aromáticos
- 5 Exponentially Weighted Moving Average

# Buscá todo sobre el shale en nuestra web



LOS NO CONVENCIONALES OPORTUNIDAD QUÍMICOS SISMICIDAD USO DEL AGUA



[www.shaleenargentina.org.ar](http://www.shaleenargentina.org.ar)

El sitio del IAPG destinado especialmente a los hidrocarburos de reservorios no convencionales, como *shale gas* y *shale oil*.

Pensada como herramienta útil para toda la comunidad, especializada o no, que quiera conocer con mayor profundidad lo relativo a estos reservorios y al *fracking* o estimulación hidráulica, así como los aspectos que generan mayores cuestionamientos: el uso del agua, la protección de los acuíferos, el uso de químicos, etcétera.

Toda la información de los expertos y las últimas noticias.

¡Y además, la posibilidad de consultar interactivamente a un experto sobre cualquier aspecto relacionado con el shale en la Argentina!





# Inteligencia Artificial en el análisis automático de imágenes aplicado a la inspección de líneas eléctricas aéreas y estaciones transformadoras

El uso de inteligencia artificial en el análisis automático de imágenes permite optimizar la inspección de líneas aéreas y estaciones transformadoras, reduciendo fallas, tiempos de respuesta y riesgos operativos.



Por **Martin Alejandro Themtham, Francisco Manuel Colombo, Miguel Moreno** (Pan American Energy)

*Este trabajo fue seleccionado en las  
3<sup>o</sup> Jornadas de Revolución Digital para Petróleo y Gas.*

**P**lanteo del Problema: Pan American Energy (PAE) presenta 4.600 km de líneas eléctricas de transmisión y distribución (T&D), en diversos niveles de tensión, siendo los principales 132 kV; 33 kV; 13,2 kV, y exhibe una continua expansión de su red eléctrica. Nuevos tendidos de electrificación en unidades de gestión (UG) como Neuquén (NQN) y Golfo San Jorge (GSJ) incrementará sostenidamente la cantidad de kilómetros a monitorear. Una red de estas dimensiones requiere de una estrecha vigilancia y una adecuada gestión de mantenimiento para garantizar su funcionamiento, su confiabilidad y disponibilidad. Aquí el reto, poder gestionar de manera acorde el mantenimiento de tal infraestructura a fin de evitar fallos y averías en el suministro eléctrico, interrupciones del servicio, pérdida de confiabilidad, impacto ambiental (contaminación por ciertas sustancias que equipos eléctricos dañados puedan liberar al medio ambiente), riesgos de seguridad (incendios, accidentes) e impactos en la infraestructura ya sea por degradaciones aceleradas, corrosión y/o daños estructurales que repercutan directamente en gastos operativos, en costos elevados de reparaciones no planificadas o por la detección tardía de problemas, como así también las interrupciones del suministro eléctrico que tengan consecuencia directa en las pérdidas de producción localizadas y no localizadas.

Para mitigar estos problemas, PAE planifica y ejecuta planes de inspección y mantenimiento regulares mediante el uso de técnicas predictivas y preventivas. Aplica, a una frecuencia fija recorridos sobre las líneas eléctricas aéreas y estaciones transformadoras, dicha inspección se efectúa tanto con patrullas a pie, como así también con vehículos aéreos no tripulados (VANT) y el uso de cámaras acústicas, termográficas y ultravioletas (UV). En dichas inspecciones se encuentran una gran cantidad de desvíos que son catalogados como fallas potenciales y luego son informados al área ejecutante de mantenimiento correctivo, con un nivel de criticidad asignado a dicho desvío (según el grado de avance de la falla y su impacto), a fin de corregir el hallazgo. Así mismo, las inspecciones sirven como soporte al área ejecutante para planificar con anticipación y programar los recursos necesarios (materiales y cuadrillas).

Conforme a los recursos que actualmente dispone PAE para realizar estas inspecciones, solo se logra cubrir 1.200 km de líneas eléctricas aéreas y alrededor de 50 estaciones transformadoras, todo en el plazo de 1 año, dejando así, una gran cantidad de activos sin inspeccionar.

Conjuntamente, la información generada bajo este esquema no es factible cumplir con el 100% del análisis en tiempo. Mes a mes se genera un backlog de imágenes pendientes de procesar, aproximadamente, solo se logra examinar el 10% de todo el volumen de información.

Hay que destacar que en promedio se capturan entre 3.000 a 5.000 fotos diarias, las cuales que son emitidas entre las patrullas a pie y cuadrillas de vuelos con VANT. Este gran volumen de imágenes debe ser correctamente clasificado, separados por etapa de vuelo, generando los logs de vuelo correspondientes, analizados los componentes de cada imagen en detalle, visualizando los desvíos que pueden encontrarse, etiquetar las imágenes y asignarle una prioridad de acuerdo al nivel de degrada-

ción del elemento o grado de avance que tiene la falla potencial dentro de la curva P-F, generar un informe por cada anomalía o activo inspeccionado, matchear el impacto que puede generar la falla funcional, cargar la información en nuestro sistema computarizado de gestión de mantenimiento (CMMS), y, mediante un aviso en SAP notificar al área ejecutante.

Por último, dadas las condiciones climáticas de la zona, las cuales muchas veces resultan limitantes para efectuar los vuelos con VANT, se alcanza, en promedio, solo medio año de vuelo efectivo. Es decir, de 250 días hábiles en 2023, solo se consiguieron inspeccionar con VANT 125 días. Algo similar para el 2022 y 2021.

Son por estas razones, que, a pesar de contar con planes de mantenimiento sólidos que reportan resultados positivos, es crucial implementar programas aún más eficientes, utilizando tecnologías avanzadas como la inteligencia artificial y la visión por computadora para mejorar la eficiencia y precisión de las inspecciones.

**Desarrollo Técnico del trabajo:** PAE lleva adelante con un RoadMap Digital dinámico como herramienta estratégica, en la que detalla su plan y dirección para conseguir la transformación digital de sus yacimientos, alcanzando una operación remota y eficiente, con planificación integrada, centralización de decisiones operativas, priorización y ejecución autónoma de tareas, que todo el conocimiento de la organización se encuentre disponible en el punto de ejecución y, con la reducción continua de la energía consumida y la exposición al riesgo de las personas.

Aquí se describen diversas iniciativas, metas, y pasos necesarios que contemplan la implementación de nuevas tecnologías y procesos digitales a lo largo del tiempo para optimizar.

Con el claro objetivo de dar solución al problema planteado, PAE incluyó el desarrollo técnico de una solución con el propósito de establecer una base sólida de análisis automático de imágenes en infraestructura eléctrica, para minimizar por un lado, el tiempo necesario en la detección de anomalías, al igual que los errores humanos, que consecuentemente deriven en fallos y averías en el suministro eléctrico y, acarren pérdidas económicas por downtime (DT), costos elevados de reparación, impacto en la infraestructura de T&D, como así también la pérdida de confiabilidad en el sistema eléctrico.

Para comenzar, se estableció la visión y los objetivos estratégicos que se pretenden alcanzar en la solución. Tal como indica el título del presente artículo, la solución radica en el uso de una plataforma que utiliza IA y mecanismos de ML en el análisis automático de imágenes aplicados específicamente a la inspección de líneas eléctricas aéreas y estaciones transformadoras.

Se detallaron las iniciativas claves, en la que se destacan 4 actividades:

1. Análisis preliminar de proveedores de solución, tanto a nivel local como internacional.
2. Armado del Caso de Negocios (CN).
3. Desarrollo de pruebas de concepto (POC) con los proveedores seleccionados por un plazo de 4 meses y su consecuente evaluación.

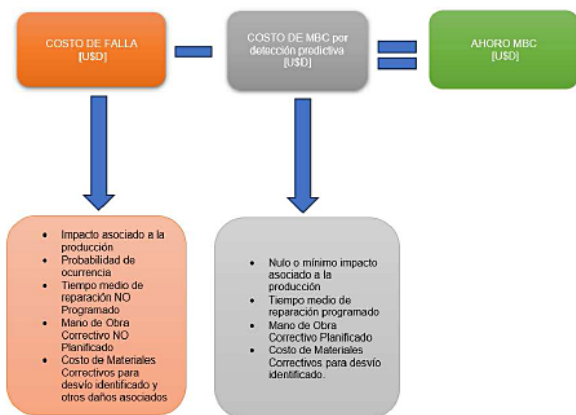
#### 4. Implementación y despliegue acelerado de la plataforma escogida en todas las UG's de PAE.

Conforme se desarrollaban las POC, se procedió a identificar los recursos necesarios (financieros, humanos, y tecnológicos) para llevar a cabo el plan, los cuales serían ajustados previo a la implementación y despliegue. Paralelamente se tomaba nota de las dependencias entre diferentes soluciones y los riesgos potenciales asociados con la implementación.

En la 1er etapa de estudio de mercado, se realizó el análisis de oferta de proveedores que prometan una solución eficaz, segura y adaptable a las necesidades de PAE. Para la selección de aquellos que participarían de las siguientes etapas, se tuvo en cuenta factores importantes tales como: capacidades técnicas, experiencia (historial, casos de éxito) y reputación en el mercado, flexibilidad, adaptabilidad y personalización, escalabilidad, soporte técnico, capacitación, cumplimiento normativo (regulaciones, normativas, seguridad del dato), innovación, mejoras y actualización, integración de la solución y facilidad de uso, además de otros aspectos técnicos y comerciales. Vale mencionar que muchos de estos puntos fueron analizados en mayor profundidad dentro de la etapa 3- Desarrollo de POC.

En la 2da etapa, para el armado del CN, se establecieron diferentes hipótesis, con asiento en los historiales de fallas registradas y catalogadas que exhibe PAE en sus bases de datos. Se analizaron bancos de datos de hasta 6 años atrás, que incluían listados de fallas en el sistema eléctrico, sus causas y los tiempos de DT directo asociado, las pérdidas post-corte, el impacto en la mano de obra ejecutante de las correcciones. También se entrevistó a personal operativo, cuadrillas, supervisores y líderes de área, con el objetivo de validar las hipótesis y minimizar los riesgos de errores estadísticos en los cálculos.

Con todo esto se establecieron 2 escenarios, uno de mínima y otro de máxima. En el primero, se contempló un porcentaje de asertividad menor, es decir un mínimo de anomalías detectadas/desvíos reales, mediante la plataforma. Además, un ahorro potencial anual que incluye los ahorros obtenidos de muestras promedio anuales de hallazgos con prioridad urgente, alta y media. También se consideró el costo actual de mantenimiento (cuadrillas y analistas), e igualmente se adicionó un factor de derrateo anual por reducción de ahorro estimado. En cambio, para el escenario de máxima, el porcentaje de asertividad considerado fue mayor, el ahorro potencial anual incluye, además de los ahorros indicados en el escenario de mínima, los obtenidos por hallazgos con prioridades baja y muy baja, un costo de mantenimiento bajo un cambio de estrategia, en el cual se planteó incrementar la cantidad de cuadrillas de inspección por VANT y expandir la inspección al 100% de las líneas eléctricas aéreas de 13,2 kV, como así también la optimización de recursos, mejora en los tiempos por misión de vuelo y la reducción de carga horaria de analistas. Conviene resaltar que hemos determinado el costo promedio anual de DT directo por fallas posibles de detectar bajo inspección por VANT, en las líneas eléctricas que actualmente no están siendo inspeccionadas.



• **Costo de Falla:** refiere al valor de costo una vez ocurrida la falla (falla funcional), sin haber sido detectada.

$$PO * \left\{ \left( IP \left[ \frac{USD}{d} \right] \right) * MTTR[d] + MO_{FALLA}[USD] + MAT_{FALLA}[USD] \right\} = Costo de Falla [USD]$$

• **Costo MBC:** refiere al valor de costo de mantenimiento correctivo cuando el desvío es detectado y se evita la falla funcional.

$$\left( IP \left[ \frac{USD}{d} \right] \right) * \frac{MTTR}{3} [d] + MO_{MBC}[USD] + MAT_{MBC}[USD] = Costo MBC [USD]$$

Siendo:

- **PO: Probabilidad de Ocurrencia** - Se basa en la asignación de una probabilidad promedio en caso de materializarse el fallo según el grado de prioridad previamente asignado al desvío detectado. Es un valor adimensional.
- **IP: Impacto en la producción** - Este valor se obtiene de la sumatoria de la producción efectuada en Gas [m3/d] y Petróleo Neto [m3/d]. Ambos considerados en hembras equivalentes [USD/d]
- **MTTR: Tiempo medio de Reparación** - Siendo este el tiempo medio de reparación entre el periodo que el equipo entra en parada programada por mantenimiento o parada por falla funcional, hasta que este es puesto nuevamente en servicio. Incluye el tiempo de búsqueda e identificación de la falla, tiempos varios (activación de cuadrilla, tiempo de viaje, el tiempo neto de reparación).
- **MO: Mano de Obra** - Considera el costo de Mano de Obra (es decir costo de cuadrilla/s) involucrada en el mantenimiento correctivo del desvío identificado.
- **MAT: Materiales** - Especifica el costo de los materiales asociados a cada tarea correctiva.

Figura 1. Cálculo de ahorros potenciales por la aplicación de estrategias de mantenimiento basado en condición (MBC).

Así también, resulta notable que el ahorro potencial anual es una métrica que se obtuvo de analizar una muestra representativa de una población de 2 años de hallazgos (3.267 avisos) con diferentes prioridades. Este ahorro se calculó por desvío detectado y acción ejecutada en campo para su normalización. Para cada detección se tiene:

En la etapa 3, Desarrollo de POC, se contrató a los 3 mejores proveedores surtidos de la primera instancia y durante un plazo de 4 meses, se los sometió a las mismas condiciones de pruebas bajo datasets previamente armados que contemplaban imágenes con los 4 casos de uso presentes más frecuentes en nuestras operaciones (fallas por burlonería, ataduras sueltas, puntos calientes, fallas superficiales en aisladores cerámicos y poliméricos). Para el cumplimiento de las POC, PAE dispuso 1,98 TB de imágenes en alta resolución (5184 x 3888 pixeles). Se incluyeron fotos en Zoom; Wide; Thermal, y cada imagen con su metadata correspondiente. De este total de imágenes solo se cargaron 415 Gb ( 40.000 fotos) en las plataformas por cuestiones de tiempo y configuraciones. También se puso a disposición informes tipo de anomalías, procedimientos utilizados en la captura imágenes y una dedicación promedio de Analista 3hs/día por proveedor a lo largo del periodo de la POC.

En paralelo se realizaron pruebas de navegación, de

carga de imágenes, de feedback para el reentrenamiento. Se visualizó la confección de dashboards a medida. Se asistió técnicamente a cada uno de los proveedores y se lograron significativos avances con todos ellos. Al finalizar las POC, fueron evaluados mediante un análisis FODA, una comparativa de cualidades entre plataformas y, por último, en base una matriz de valorización con diferentes pesos asignados a cada línea. Los ítems evaluados son listados a continuación:

- Por cada modo de falla y dataset de testeo cargado: Exactitud (Accuracy); Exhaustividad (Recall); F1 SCORE; Tasa Falsos Positivos (FPR); Precisión.
- Facilidad de carga de imágenes y tiempo de análisis.
- Experiencia Usuario y plataforma (navegación, interfaz, gestión - reconocimiento de anomalías + historia, etc.).
- Soporte y Capacitación.
- Visualización de la anomalía identificada y asignación de la severidad de la anomalía.
- Gestión KPI.
- Identificación del piquete.
- Exportación de datos (Excel o CSV).
- Facilidad de configuración de nuevos MDF.
- Reentrenamiento.
- Flexibilidad de la plataforma ante cambios visuales.

	ANOMALIAS BURLONERÍA SUELTA / FALTANTE			ANOMALIAS PUNTOS CALIENTES			ANOMALIAS AISLADOR CERAMICO		
	SOLUCIÓN 1	SOLUCIÓN 2	SOLUCIÓN 3	SOLUCIÓN 1	SOLUCIÓN 2	SOLUCIÓN 3	SOLUCIÓN 1	SOLUCIÓN 2	SOLUCIÓN 3
Exactitud	20,18%	78,97%	17,69%	N/A	25,84%	7,69%	57,14%	56,56%	18,75%
Precisión	52,04%	51,30%	8,54%	N/A	33,33%	33,33%	33,73%	80,00%	14,47%
Recall (sensibilidad, exhaustividad)	18,95%	82,29%	17,95%	N/A	13,64%	2,86%	62,22%	57,14%	14,47%
Tasa FP	74,60%	24,24%	82,42%	N/A	62,50%	50,00%	44,72%	50,00%	77,38%
Medida F1	27,79%	63,20%	11,57%	N/A	19,35%	5,26%	43,75%	66,67%	14,47%
	ANOMALIAS AISLADOR POLIMÉRICO			SIN FALLAS			IDENTIFICACIÓN DE COMPONENTES		
	SOLUCIÓN 1	SOLUCIÓN 2	SOLUCIÓN 3	SOLUCIÓN 1	SOLUCIÓN 2	SOLUCIÓN 3	SOLUCIÓN 1	SOLUCIÓN 2	SOLUCIÓN 3
Exactitud	20,31%	N/A	27,27%	81,63%	58,39%	N/A	85,18%	59,84%	N/A
Precisión	23,67%	N/A	33,33%	15,94%	2,13%	N/A	91,48%	93,75%	N/A
Recall (sensibilidad, exhaustividad)	41,61%	N/A	43,59%	84,62%	8,33%	N/A	68,99%	52,50%	N/A
Tasa FP	94,74%	N/A	89,47%	18,49%	36,80%	N/A	60,53%	12,96%	N/A
Medida F1	30,18%	N/A	37,78%	26,83%	3,39%	N/A	78,66%	67,31%	N/A
	ALEATORIO								
	SOLUCIÓN 1	SOLUCIÓN 2	SOLUCIÓN 3						
Exactitud	85,03%	89,03%	42,86%	Mide cuánto se aproximan los resultados al valor verdadero (Proximidad entre un valor medido y un valor verdadero del mensurando)					
Precisión	41,51%	23,57%	9,62%	¿Qué proporción de los clasificados como positivos lo son realmente?					
Recall (sensibilidad, exhaustividad)	62,86%	89,19%	41,67%	Mide la habilidad del modelo para detectar valores positivos verdaderos					
Tasa FP	11,97%	10,97%	56,97%	¿Qué proporción de todos los positivos se clasifican como tal?					
Medida F1	50,00%	37,29%	15,63%	Los buenos modelos tienen FPR muy bajo					
				Cuanto mayor sea el valor de F1, mejor será el rendimiento del modelo					

Tabla 1. Valores de asertividad obtenidos para diferentes proveedores en función de los dataset cargados.

La POC resultó una etapa crucial de cara a la implementación, ya que permitió la validación de la viabilidad técnica, la identificación de problemas antes de la implementación a gran escala, la mitigación de riesgos por pruebas en un entorno controlado. Fue concluyente para determinar si esta nueva tecnología optimizaría el uso de recursos frente al proceso actual, incluyendo el tiempo de análisis. Determinó si sería la facilitación de una integración fluida, evaluando la compatibilidad de la nueva tecnología con los sistemas y procesos existentes y cuanto admiten de customización o soluciones personalizadas, con el fin de adaptar mejor la solución a las necesidades y circunstancias específicas de PAE. Otro factor no menor, que posibilitó la POC, fue la evaluación de la aceleración del proceso de implementación, mediante la reducción del tiempo de despliegue. Por último, la POC impactó en la medición de beneficios potenciales de la tecnología, como mejoras en la eficiencia, reducción de costos y aumento de la cantidad de hallazgos, como así también en el análisis de desempeño de la solución en condiciones reales, asegurando que cumple con las expectativas y objetivos establecidos.

Previa a pasar a la siguiente fase, etapa 4- Implementación y despliegue acelerado de la plataforma escogida, se elaboró un anexo técnico (AT) que incluyó mejoras requeridas respecto de la POC, se añadió lo mejor de cada plataforma testeada. Se solicitó la adición de todos los modos de fallos catalogados en nuestro sistema SAP, el armado de dashboards y KPI's customizados, la facilidad de realizar una planificación centralizada desde plataforma, la conectividad con SAP y otras aplicaciones, la asignación de severidad según estándar PAE, el cumplimiento de un plan de despliegue agresivo para dar cobertura en todas las UG's de PAE.

Para comparar las ofertas técnicas, se utilizó la misma metodología que en la POC, se confeccionó una matriz de valoración, se asignó un peso a cada línea evaluada y se procedió con el análisis. Los ítems técnicos evaluados fueron:

- Velocidad de Despliegue / Seguimiento del cronograma propuesto.
- Analítica de Imágenes y Videos.
- Catálogo de Fallos (Inclusión de todos los MDF).
- Dashboards customizables / Tablero de Gestión de alarmas (considera calidad, funcionalidad y tiempo de respuesta).
- Herramienta de Inspección (relinqueo, vistas, asignaciones de estados, planificación de misiones, identificación de componentes, kpi's, feedback, visualización y comparación de históricos).
- Facilidad de carga de datasets.
- Disponibilidad y recursos comprometidos en el proyecto.
- Alcance Funcional (escalabilidad, flexibilidad, velocidad, correcciones, visualización cartográfica de red eléctrica).
- Alcance de activos de inspección.
- Conectividad bidireccional con SAP.
- Conectividad con otras herramientas y aplicaciones.
- Utilización de inputs externos a PAE para entrenamiento de modelos.

- Generalidades (incluye navegación, interfaz, entregables comprometidos; soporte y capacitación; experiencia Customer Success Manager; experiencias anteriores y knowhow del servicio; HDR a futura).
- MDF primarios y secundarios – Asertividad esperada en función de inputs.
- Informe y registros solicitados por PAE - Exportación de datos.
- Reentrenamiento / Etiquetado.
- Cantidad de Usuarios / Perfiles y Roles definidos.
- Flexibilidad y respuesta ante cambios visuales de la plataforma.
- Seguridad de información - Requisitos IT.
- IA Generativa.
- Tiempo establecido y carga HH requerida para cumplimiento de objetivo proyecto al 100% (análisis automático de imágenes); Nivel de dependencia de PAE (HH requeridos).

Resultados obtenidos: En general, los modelos de IA obtuvieron buenos resultados en la identificación de componentes y defectos, teniendo en cuenta que algunos modelos de IA de los proveedores nunca habían sido entrenados en estos activos. Aquellos modelos que fueron armados y entrenados con datasets de fallas provistos por PAE lograron excelentes resultados a pesar de no superar las 1.200 imágenes con fallas por cada caso de uso. En algunos modos de fallos superaron el 80% de asertividad.

Se consiguió validar técnicamente la aplicación de más de una plataforma funcional para optimizar las inspecciones en PAE y realizar un escalamiento de la solución.

Los logros más destacables en comparación con el proceso actual son:

- 95% mejora del proceso integral.
- 3X más defectos detectados que el método actual.
- 100% imágenes analizadas.
- 4X veces más veloz el análisis de imágenes.
- Disminución del tiempo de registro y calificación a 1/3 del utilizado en la actualidad.
- Comparación inmediata de datos históricos para evaluar la evolución de un defecto en el tiempo.
- Aprovechamiento de los datos para planificar el mantenimiento.
- Visión más amplia del ciclo de vida de los activos.

Es preciso mencionar que el CN fue actualizado con la oferta económica del despliegue del proyecto, que contempló el valor real del licenciamiento e implementación de la plataforma funcional. El VAN del proyecto es positivo, su TIR es de 240% y el valor de repago del proyecto es de 1,4 años.

## Conclusiones

Las inspecciones virtuales con el uso de IA suponen un paso evolutivo en el viaje de digitalización. El primer objetivo del proyecto debe buscar la aceleración de las

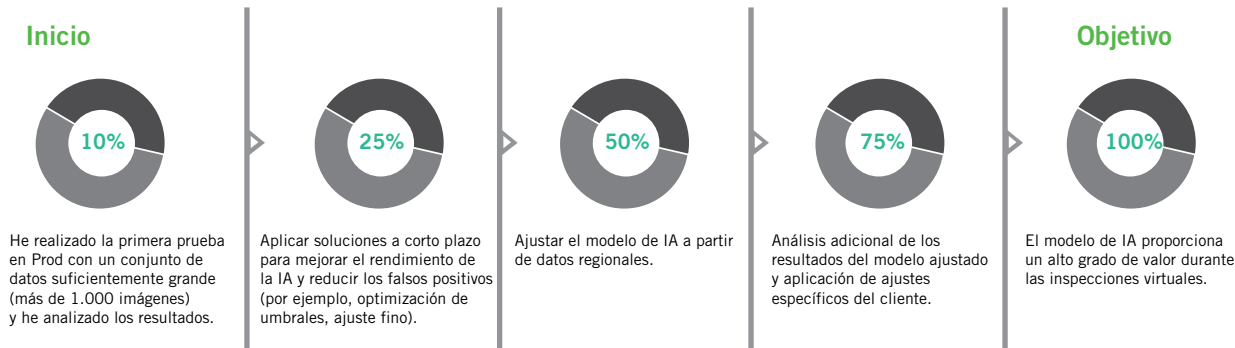


Gráfico 2. Ejemplo de viaje del modelo de IA.

inspecciones virtuales y la detección de defectos al utilizar una IA colaborativa, es decir que no reemplazar en su totalidad la intervención humana, sino que hacer de esta última más eficiente y precisa.

En general, hay múltiples factores que influyen en el rendimiento de la IA, estos factores críticos incluyen la captura de imágenes, la calidad de la imagen, el reentrenamiento, el ajuste de umbrales, la definición de defectos y la entrada de datos estándar. Por tal razón, es preciso aplicar una metodología probada para establecer las bases para la mejora continua de la IA.

Se recomienda que la plataforma abarque la mayor parte del proceso, permitiendo al cliente planificar la captura de imágenes y las inspecciones en una sola herramienta.



La evaluación de los proveedores debe ser exhaustiva y considerar tanto las capacidades técnicas como los aspectos comerciales y operativos. Todos estos puntos

favorecerán a un despliegue rápido, efectivo y con el menor nivel de dependencia por parte del cliente.

Otro punto relevante refiere a que, para medir eficazmente el aumento de la eficiencia, es necesaria una métrica que tenga en cuenta el tiempo ahorrado al aceptar las sugerencias correctas de la IA y el tiempo perdido en revisar y rechazar las sugerencias de la IA. Muchas veces el esforzarse por conseguir una precisión perfecta podría obligar a la IA a ignorar sugerencias cuando no está segura, con el riesgo de perder automatización y requerir el registro manual de defectos. Del mismo modo, aspirar a un recall perfecto podría abrumar a los analistas con demasiadas sugerencias, lo que mermaría la eficacia. En cambio, optimizar la eficiencia permitiría a la IA sugerir un número razonable de casos para su inspección, dando prioridad a un ahorro de tiempo significativo frente a una precisión y exhaustividad perfectas. Encontrar el equilibrio adecuado entre automatización y dedicación del analista es clave. Aunque la automatización de la detección de defectos puede parecer beneficiosa, puede suponer una pérdida de tiempo para los inspectores si tienen que revisar numerosas sugerencias. Por lo tanto, lo mejor es encontrar un equilibrio que dé prioridad al aumento de la eficacia y al ahorro de tiempo.

Por último, hay que destacar que la implementación de la IA en el análisis automático de imágenes para la inspección de líneas eléctricas aéreas y estaciones transformadoras representa un avance significativo en la gestión y mantenimiento de infraestructuras eléctricas.

Este enfoque innovador ofrece numerosos beneficios, entre los que destacan la mejora en la precisión y eficiencia de las inspecciones, la reducción de costos operativos y la mitigación de riesgos.



Capturas de casos de usos identificados en la plataforma.



# Mejora de la eficiencia operativa en equipos de producción de gas: detección temprana de eventos de erosión con modelos de *Machine Learning (ML)*

Por **Camila Sabrina Juan Suriano; Jaime Andrés Vega Becerra** (Practia), **Julio Sandoval; Cristian Grau Viñolo; Ignacio Mason** (Tecpetrol).

El uso de modelos de Machine Learning permite anticipar fallas por erosión en equipos clave de producción de gas, mejorando la eficiencia operativa y reduciendo riesgos. Este enfoque reemplaza el monitoreo tradicional con soluciones predictivas basadas en datos. Una innovación clave para garantizar la seguridad y continuidad de las operaciones.



## Planteo del problema

En la industria del petróleo y gas, el aseguramiento del flujo de los pozos y la salud de los equipos de producción son temáticas de vital importancia debido a los altos costos asociados a las pérdidas de producción y a los costos de los equipos.

A partir del año 2020, comenzaron a ocurrir fallas por erosión en los calentadores de los PAD's. Estos eventos, además de los costos asociados mencionados anteriormente, también presentaban un alto riesgo en cuanto a seguridad de las operaciones. Por ello, se decidió abordar el problema, buscando una solución innovadora que permitiera mitigar estos efectos.

Hasta ese momento, la única forma de detectar señales previas de erosión en las instalaciones era mante-

ner un operador de sala, encargado de monitorear todas las variables físicas de los activos, aunque los indicios capturados a partir de este monitoreo eran detectables solamente si se materializaban de manera abrupta y en algunos casos con el evento de falla ya teniendo curso

Por ende, se buscó ir más allá, y explorar que información adicional se podría obtener a partir de los datos disponible. En este contexto, surgió la inclusión de la ciencia de datos como herramienta para alcanzar una posible solución.

## Desarrollo técnico del trabajo

A partir de la aparición de varios eventos de fallas causados por erosión en los chokes de calentadores (como la pérdida de contención primaria de fluidos del pozo), se decidió buscar una solución para prevenir estos incidentes mediante la generación de alertas que permitan actuar de forma preventiva. Dado que se disponía de información sobre múltiples variables físicas de los equipos (por ejemplo, temperatura, presión, etc.), se optó por explorar la utilización de modelos de machine learning supervisados como posible solución.

La clasificación supervisada es una rama del aprendizaje automático que se basa en el uso de un conjunto de datos de entrenamiento etiquetados para enseñar a un algoritmo cómo clasificar nuevos datos de entrada [1]. Para poder entrenar este tipo de algoritmos, es necesario contar con datos etiquetados, es decir, se precisa tener fallas detectadas con sus tiempos respectivos. Esta particularidad es de suma importancia, dado que, si bien se contaba con la detección visual de la falla, dicha detección era efectuada de forma manual y mientras el pozo se encontraba cerrado, adjudicándose una temporalidad posterior a la ocurrencia de esta. Este factor impulsa la necesidad de detectar y aislar un comportamiento característico previo dentro de la información en el análisis de datos históricos de presión y temperatura. La primera etapa de este proceso (Figura 1) involucró la recopilación y preprocesamiento de datos, asegurando que toda la información relevante estuviera limpia y adecuadamente estructurada. Esto incluyó la eliminación de valores atípicos, la imputación de datos faltantes y la normalización de las variables para estandarizar las unidades de medida y facilitar el análisis subsecuente. Esta fase de preprocesamiento de datos en Machine Learning es esencial para garantizar la calidad y eficacia de los modelos [2].

Una vez preparados los datos, se procedió al análisis descriptivo de las series temporales de los pozos en producción. En esta etapa, el factor clave fue la evaluación minuciosa del comportamiento de las principales curvas, presión y temperatura, previos a la ocurrencia de la falla, con el fin de detectar algún cambio característico a partir del cual comenzara a ocurrir la falla. Este hito de cambio marcaría el punto de inicio mediante el cual sería posible aislar el tramo de falla, de manera de etiquetarlo para poder entrenar al modelo supervisado con el comportamiento característico de la misma. Tras el análisis



Figura 1. Metodología empleada en la resolución del problema.

riguroso de varios eventos de falla ocurridos, fue posible aislar un cambio notorio en las pendientes de la presión y la temperatura previos a la detección de la falla. Si bien este cambio de pendiente podría ocurrir de forma más o menos acelerado, dicho cambio fue detectado y aislado en todos los casos analizados (Figura 2).

Con el objetivo de poder identificar este cambio de forma más precisa, se emplearon técnicas provenientes del análisis de series temporales para poder obtener, mediante descomposición aditiva, la tendencia que describe a las curvas analizadas y permitiendo disminuir el ruido presente en estas mismas. Este tipo de descomposición es la aconsejada a emplear en casos donde la magnitud de la estacionalidad no aumenta con el tiempo, pues en ese caso se debería utilizar la descomposición multiplicativa [3]. A partir de la tendencia obtenida, se calcularon las derivadas primera y segunda, permitiendo detectar así los cambios visualizados, automatizando la detección del inicio de cada falla. Este análisis preliminar proporcionó el poder de distinguir entre comportamiento normal y anómalo de los sistemas bajo estudio, sentando las bases para el desarrollo del modelo predictivo. Partiendo de la detección del inicio de falla, se generaron las etiquetas de estos intervalos prolongándose desde ese inicio hasta la indicación de cierre de pozo.




Figura 2. Comportamiento observado previamente a la detección de la falla

El siguiente paso en la metodología fue el desarrollo y entrenamiento del modelo de Machine Learning de clasificación. El desafío principal radicaba en el desequilibrio de datos de fallas frente a las condiciones operativas normales, lo que condujo al sobreajuste cuando se utilizaron técnicas tradicionales de aprendizaje supervisado. Se ha demostrado que los modelos de aprendizaje supervisado, como los basados en técnicas de ensamble, son robustos y capaces de manejar datos desbalanceados [4] y [5]. A pesar de las fortalezas mencionadas, los modelos sobreajustaban los datos de entrenamiento, especialmente al intentar generalizar en diferentes pozos. Con el fin de resolver esta situación, se utilizaron técnicas de remuestreo, pero no dieron resultados satisfactorios. El problema se agravó por la alta variabilidad entre diferentes pozos, lo que causaba que los modelos fallaran cuando se aplicaban a pozos no incluidos en el conjunto de entrenamiento. Para abordar estos desafíos, fue planteada la hipótesis de que la variabilidad entre los pozos estaba contribuyendo al problema del sobreajuste.

Finalmente, con el fin de mejorar la detección de fallas, se implementó una metodología en dos fases. En la primera fase, se llevó a cabo la clasificación no supervisada de los pozos. Para ello, se recolectaron los datos de todos los pozos, que incluían las instancias normales. Luego, se utilizó una técnica basada en redes neuronales auto-organizativas para agrupar los pozos en un mapa bidimensional de características [6]. Posteriormente, se aplicó una técnica de clustertización sobre las neuronas para identificar clusters de pozos [7]. Este enfoque permitió agrupar pozos con características similares y desarrollar modelos personalizados para cada cluster. En la segunda fase, se llevó a cabo la clasificación supervisada para la detección de fallas. Con este fin, fueron entrenados modelos supervisados separados para cada grupo de pozos preagrupados, utilizando los datos de entrenamiento específicos de cada grupo de pozos similares. Luego se realizó la validación a partir de dejar un pozo fuera de los clusters para asegurar la robustez. Asimismo, se proba-



Figura 3. Señal de alerta generada por el modelo

ron los modelos en pozos dentro del mismo cluster para evaluar la mejora en el rendimiento [4] y [5], es decir, si en un cluster había  $N$  pozos, se dejaba uno fuera y se entrenaba con los  $N-1$  pozos restantes, probando con el pozo restante. Es importante destacar que la predicción se consideraba correcta si el modelo predecía tempranamente la falla e incorrecta si no lo hacía. Por otro lado, para evitar generar alertas cortas y recurrentes asociadas con falsos positivos del modelo, se tomó la decisión de considerar la alerta válida luego de extenderse al menos durante 2 horas, siendo este el intervalo empleado tanto en la obtención de la tendencia por descomposición aditiva como del cálculo de derivadas. Esto significa que debe contarse con al menos un histórico de 2 horas de datos para poder correr el modelo correctamente. En la Figura 3 se evidencia como es la visualización final de alerta en función del tiempo, tomando como referencia la curva de presión.

## Resultados obtenidos

Dentro de los principales resultados obtenidos, se destacan los siguientes puntos:

- La implementación del modelo de Machine Learning desarrollado para la detección temprana de fallas en el choke de producción arrojó resultados prometedores basándose en la validación mediante blind tests (aplicación del modelo a un conjunto de datos históricos no empleados dentro del entrenamiento inicial). Este modelo logró identificar más del 60% de los eventos de falla antes de su ocurrencia, lo que evidencia su capacidad para predecir fallas de manera efectiva. Estos resultados no solo demuestran la viabilidad de utilizar técnicas avanzadas de análisis de datos en el monitoreo de equipos estáticos, sino que también subrayan la importancia de una gestión proactiva en la industria del petróleo y gas.
- Tras el análisis desarrollado se comprobó que las derivadas primera y segunda de las curvas de presión y temperatura fueron indicadores críticos en la identificación de cambios en las tendencias operativas, que preceden a las fallas.
- El modelo fue capaz de distinguir entre el comportamiento normal y anómalo de los sistemas, permi-

tiendo una intervención temprana para evitar eventos que podrían ser severos desde el punto de vista de la seguridad y reducir el tiempo de inactividad.

Actualmente el modelo está siendo optimizado a partir de la mejora en la definición de las etiquetas y mediante la incorporación de nuevos casos, sumando más información al entrenamiento y mejorando su capacidad de generalización.

## Conclusiones

Los hallazgos sugieren que la variabilidad entre los pozos es un factor crítico que contribuye al sobreajuste en las tareas de detección de fallas. Este desafío fue resuelto mediante el uso de la técnica de clusterización para agrupar pozos similares antes de aplicar modelos supervisados. Este enfoque aseguró que los modelos fueran más adecuados para las condiciones específicas de cada cluster, mejorando así la precisión en la detección. Además, la combinación de técnicas no supervisadas permitió una preclasificación efectiva de los pozos, facilitando el entrenamiento y la validación de modelos supervisados dentro de cada cluster.

La capacidad del modelo para distinguir entre comportamientos normales y anómalos en las curvas de presión y temperatura ha permitido intervenir tempranamente, evitando eventos potencialmente severos y reduciendo significativamente el tiempo de inactividad. Esto no solo mejora la seguridad operativa, sino que también optimiza la productividad y minimiza los costos asociados a interrupciones inesperadas en la producción. Este resultado subraya la viabilidad de aplicar técnicas avanzadas de análisis de datos en el monitoreo de equipos estáticos, promoviendo una gestión operativa más proactiva.

En resumen, la implementación del modelo de Machine Learning desarrollado para la detección temprana de fallas en el choke de producción ha demostrado ser una herramienta eficaz para la industria del petróleo y gas.

## Bibliografía

- [1] 6 Métodos de clasificación | Estadística y Machine Learning con R (bookdown.org)
- [2] <https://iartificial.blog/aplicaciones/la-importancia-del-preprocesamiento-de-datos-en-el-machine-learning/>
- [3] "Descomposición de Series Temporales" (<https://es.planetcalc.com/7910/>)
- [3] Breiman, L. (2001). Random Forest. *Machine Learning*, 45(1), 5-32. doi:10.1023/A:1010933404324
- [5] Chen, C., Liaw, A., & Breiman, L. (2004). Using random forest to learn imbalanced data. University of California, Berkeley.
- [6] Kohonen, T. (1990). The self-organizing map. *Proceedings of the IEEE*, 78(9), 1464-1480. doi:10.1109/5.58325
- [7] MacQueen, J. (1967). Some methods for classification and analysis of multivariate observations. *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, 1, 281-297.



# Aplicación de inteligencia artificial para el análisis de facies sedimentarias

Por **Isabel Eugenia Giannoni**, **Mariano Germán Arregui**, **Augusto Nicolas Varela** (Y-Tec y CONICET) y **Javier Vásquez** (YPF).

*Este trabajo fue seleccionado en las 3º Jornadas de Revolución Digital para Petróleo y Gas.*



**El uso de inteligencia artificial y machine learning permite clasificar facies sedimentarias con mayor precisión, reduciendo la subjetividad del análisis. Esta herramienta acelera el estudio de testigos de roca y mejora la comprensión de los ambientes sedimentarios.**

Las facies sedimentarias, un concepto fundamental en geología, refiere a las características físicas, químicas y biológicas de una unidad de roca sedimentaria que se formó por un proceso sedimentario específico. Estas características incluyen la textura, composición y estructuras sedimentarias (mecánicas y biogénicas) presentes en la roca (Walker, 2006). La definición y estudio de facies sedimentarias y sus asociaciones resulta especialmente útil en la exploración y explotación de hidrocarburos y otros recursos, donde la comprensión del paleoambiente sedimentario es fundamental para la toma de decisiones, como fue planteado por Miall (1977, 1988).

La Inteligencia Artificial (IA) se ha convertido en la base de numerosas aplicaciones actuales que van desde

el diagnóstico médico personalizado hasta los vehículos autónomos y la personalización de contenidos en línea; transformando así la manera en que interactuamos con la tecnología y abordamos desafíos en diversos campos (Juca-Maldonado, 2024). Dentro de la geología, en campos como la sedimentología y la petrografía, ha permitido realizar análisis más rápidos, precisos y detallados de las rocas (Eftekhari et al., 2024; Germay et al., 2023; Gonçalves et al., 2017; Holden et al., 2023; Ippolito et al., 2021; Mancini et al., 2020).

El objetivo del presente trabajo es el uso de la IA, específicamente de Machine Learning (ML), a imágenes de alta y baja resolución de muestras de testigos coronas, datos geoquímicos y perfiles de resistencia a la rotura




Figura 1. (A) Extracción de texturas de la imagen a partir de imágenes de baja resolución en profundidad. (B) Extracción de texturas de la imagen a partir de imágenes de alta resolución en profundidad.

(scratch test machine) con el fin de clasificar, inferir y predecir patrones de comportamiento asociados a las facies con sus correspondientes procesos y ambientes sedimentarios.

Tradicionalmente, los sedimentólogos han empleado métodos manuales para clasificar y describir los diferentes tipos de sedimentos/sedimentitas presentes en muestras, el cual es un proceso laborioso y muchas veces subjetivo. Sin embargo, mediante el uso de estas técnicas de procesamiento de imágenes comprendidos dentro del subcampo del ML supervisado y no supervisado, los algoritmos pueden analizar imágenes de los testigos de rocas y clasificarlos automáticamente en categorías predefinidas. Esto reduce la subjetividad del observador, mejorando la precisión de las clasificaciones, además de disminuir los tiempos de descripción; permitiendo comparar de manera directa las descripciones de diferentes observadores.

El proceso de análisis consistió en varias etapas, en las que se buscó asegurarse de describir los diferentes tipos de sedimentos/sedimentitas presentes en muestras, el cual es un proceso laborioso y muchas veces subjetivo. Sin embargo, mediante el uso de estas técnicas de procesamiento de imágenes comprendidos dentro del subcampo del ML supervisado y no supervisado, los algoritmos pueden analizar imágenes de los testigos de rocas y cla-

sificarlos automáticamente en categorías predefinidas. Esto reduce la subjetividad del observador, mejorando la precisión de las clasificaciones, además de disminuir los tiempos de descripción; permitiendo comparar de manera directa las descripciones de diferentes observadores. la calidad de la información. Inicialmente se describieron digitalmente y reconstruyeron las 42 diferentes facies sedimentarias de 84 metros de testigos de rocas de un set de datos sintéticos cedido por la empresa EPSLOG S.A en el marco del convenio de colaboración firmado oportunamente con Y-TEC S.A. El set sintético de datos fue recopilado de manera tal que las rocas seleccionadas respondan a los diversos procesos y paleoambientes sedimentarios que se dan en la naturaleza. Esto se logró combinando diferentes metros de diferentes pozos sobre los cuales la compañía EPSLOG S.A realizó servicios.

Para la nomenclatura de dichas facies sedimentarias, se utilizó una denominación basada en Miall (1977, 1988) para rocas clásticas, mientras que para las rocas carbonáticas se utilizó Dunham (1962), ampliada por Embry y Klován (1971) y modificada luego por Lokier y Al Junaibi (2016).

Luego, se realizó el análisis de las imágenes de testigos coronas, tanto de alta como de baja resolución. Para pasar de imágenes RGB, cuya dimensión posee 3 capas a una matriz plana unidimensional se decidió realizar una

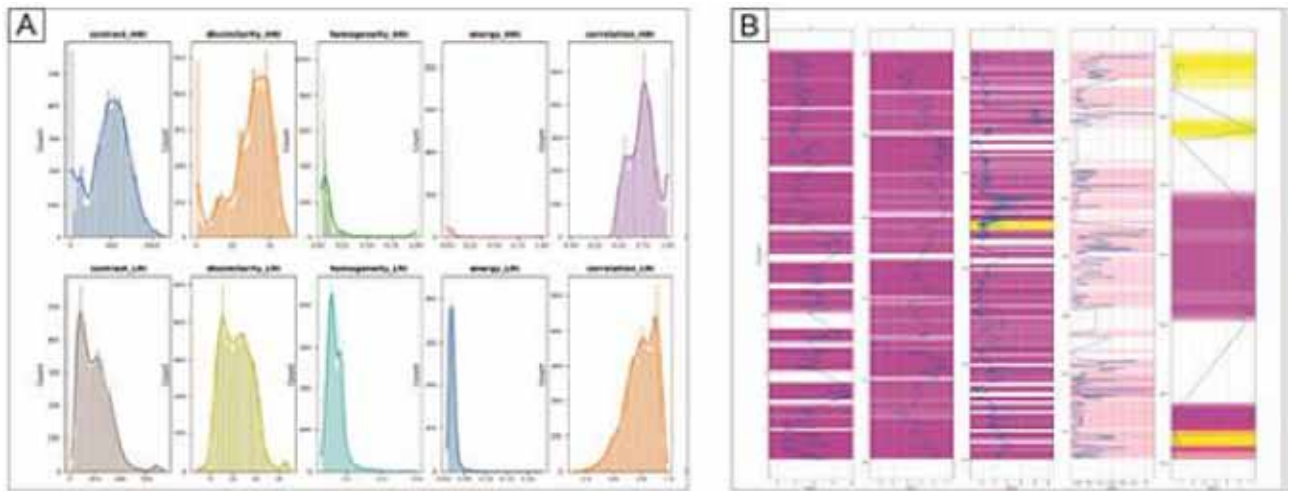


Figura 2. (A) Análisis univariado de la distribución de cada variable; (B) Análisis univariado de cada elemento en profundidad y composición.

segmentación centímetro a centímetro y la obtención de un grupo de propiedades (contraste, homogeneidad, segundo momento angular o ASM, correlación, disimilitud, heterogeneidad, energía, entropía), que surgen del análisis textural de la imagen en función de la profundidad (Fig.1 A y B). Para que los análisis de frecuencia de la matriz fueran representativos, se decidió observar la co-ocurrencia de los valores de los píxeles en todas las direcciones posibles (E-W, NE-SW, N-S, SE-NW) y a diferentes distancias 5, 10, 15 y 20 píxeles (Marceau et al., 1990; Marrón, 2012; Presutti, 2004).

Lo que respecta a los datos químicos, al ser obtenidos mediante fluorescencia de rayos X, fueron sometidos a la transformación necesaria para su utilización eliminando la restricción de la suma constante (Alperin, 2013; Martín-Fernández et al., 2011; Rollinson, 1993). Una vez completado la transformación necesaria para algunas de las variables, se procedió a realizar el análisis estadístico exploratorio del conjunto de datos en su totalidad teniendo en cuenta un enfoque uni, bi y multivariado (Fig.2). Se realizó una evaluación de la distribución de cada variable en profundidad para identificar zonas de interés (Fig.2 A y B), así como la correlación entre pares de elementos para identificar posibles relaciones entre ellos. Una vez obtenidas, homogeneizadas y estandarizadas todas las variables, se procedió a realizar un segundo Análisis de Componentes Principales para realizar la reducción de variables. Como resultado de este procesamiento de datos se obtuvo finalmente un data set compuesto por 17 variables a modelar y 1 variable Target (facies sedimentarias).

En la etapa de modelado, se evaluó la performance predictiva y de clasificación de diferentes modelos de ML supervisados: Extreme Gradient Boosting Machine Classification (XGBM), Logistic Regression (LG) y Random Forest Classification (RF). Como resultado, se obtuvo que el mejor predictor era XGBM con un accuracy de 0.77, a su vez se pudo observar que el segundo momento

angular de las imágenes de baja resolución, en conjunto con el Bario y el Calcio son las variables que más aportan a la construcción de las predicciones (Fig. 3).

Sin embargo, al realizar una validación a posteriori (Fig.4) se observó que, si bien las métricas del modelo eran buenas, al estar frente a muestras nunca vistas la performance no era la esperada. De un total de 120 predicciones, solo el 25 % fueron acertadas (muestras verdes en Fig. 4), siendo el otro 75% desaciertos con distintos niveles de errores. Cabe destacar que de todas las predicciones solo se ha obtenido 1 error en lo que respecta a la composición, siendo el resto de los errores anteriormente mencionados de granulometría y estructura sedimentaria. En este sentido, los errores fueron clasificados en colores dependiendo el criterio geológico: (1) los errores naranjas representan el 2.11 % y son los que poseen error de composición, textura y granulometría. Este error es considerado una predicción totalmente errónea; (2) los errores azules representan el 39.11% del total, corresponden a muestras bien clasificadas composicionalmente pero que poseen discrepancias entre las granulometrías y las estructuras sedimentarias predichas y las




Figura 3. Diagram tipo Shap donde se muestran los aportes de las distintas variables a las predicciones del modelo.






Figura 4: Predicciones del modelo para los 4 metros utilizados. En distintos colores se encuentran los distintos tipos de errores.

reales; (3) los errores amarillos corresponden al 26.11% y se consideran errores moderados, las muestras eran en su mayoría heterolíticas y si bien el modelo erra en su predicción, esta se encuentra dentro de los rangos granulométricos de la heterolítica; y por último (4) los errores rojos, que conforman el 27.11 % restante, corresponden a los considerados no graves ya que en su mayoría son limos clasificados como arenas finas y donde la estructura sedimentaria real era masiva por bioturbación, pero el modelo las considero masivas.

Podemos concluir entonces que: (1) cuando se realizan modelos de predicción de facies y procesos sedimentarios es indispensable contar con una apropiada entrada de los datos para alimentar los modelos. Para conseguir esto es necesario unificar los criterios sedimentológicos, por lo que se confeccionó un código de facies coherente, constante, homogéneo que elimine las posibles subjetividades presentes en las descripciones de distintos observadores. Tal código de facies sigue las nor-

mativas sugeridas por (Dunham, 1962; Embry & Klovan, 1971; Lokier & Al Junaibi, 2016; Miall, 1977, 1988) pero modificado ligeramente para su análisis matemático (2) el modelo entrenado tiene una buena performance para predecir las distintas composiciones a nivel centimétrico de las muestras dadas, pero posee una deficiencia moderada e importante a la hora de predecir granulometrías y estructuras sedimentarias respectivamente. Esto podría deberse que la escala de entrenamiento del modelo es demasiado pequeña para la naturaleza de las escalas de las características geológicas a predecir. Cabe destacar que muchos de estos errores a la hora de predecir facies y agrupamientos de facies muchas veces están presentes también en trabajos realizados por profesionales, sobre todo los errores clasificados como amarillos y rojos, que son los que más se prestan a confusión. Por otro lado, no debe descartarse la posibilidad que los distintos orígenes de los datos (perfiles en el caso de la composición química e imágenes para la granulometría y la estructura

sedimentaria), puedan ser factores preponderantes en la baja performance del modelo.

## Agradecimientos

El presente trabajo se realizó en el marco del proyecto DISCO2STORE, quien recibe financiamiento del programa de investigación e innovación Horizont 2020 de la Unión Europea en el marco del Marie Skłodowska-Curie grant agreement No 101007851. Los autores agradecen a EPSLog S.A por el aporte de las muestras. Así también a los tecnólogos y analistas de laboratorio de Y-TEC S.A por el análisis de los mismos.

## Bibliografía


- Alperin, M. (2013). Introducción al análisis estadístico de datos geológicos. Editorial de la Universidad Nacional de La Plata (EDULP).
- Eftekhari, S. H., Memariani, M., Maleki, Z., Aleali, M., Kianoush, P., Shirazy, A., Shirazi, A., & Pour, A. B. (2024). Employing Statistical Algorithms and Clustering Techniques to Assess Lithological Facies for Identifying Optimal Reservoir Rocks: A Case Study of the Mansouri Oilfields, SW Iran. *Minerals*, 14(3), 233. <https://doi.org/10.3390/min14030233>
- Embry, A. F., & Klovan, J. E. (1971). A late Devonian reef tract on northeastern Banks Island, NWT. *Bulletin of Canadian petroleum geology*, 19(4), 730-781.
- Germay, C., Lhomme, T., & Perneder, L. (2023). High-resolution core data and machine learning schemes applied to rock facies classification. *Geological Society, London, Special Publications*, 527(1), 121-135. <https://doi.org/10.1144/SP527-2021-193>
- Gonçalves, Í. G., Kumaira, S., & Guadagnin, F. (2017). A machine learning approach to the potential-field method for implicit modeling of geological structures. *Computers & Geosciences*, 103, 173-182. <https://doi.org/10.1016/j.cageo.2017.03.015>
- Holden, T., Kurian, R., Ibrahim, M., Hampson, D., & Downton, J. (2023). Predicting Facies, Rock, and Geomechanical Properties Using Convolutional Neural Networks: A Case Study From an Unconventional Shale Reservoir. *Proceedings of the 11th Unconventional Resources Technology Conference*. Unconventional Resources Technology Conference, Colorado Convention Center, Denver, Colorado, US. <https://doi.org/10.15530/urtec-2023-3862247>
- Ippolito, M., Ferguson, J., & Jenson, F. (2021). Improving facies prediction by combining supervised and unsupervised learning methods. *Journal of Petroleum Science and Engineering*, 200, 108300. <https://doi.org/10.1016/j.petrol.2020.108300>
- Juca-Maldonado, F. (2024). El impacto de la inteligencia artificial en los trabajos académicos y de investigación. *Revista Metropolitana de Ciencias Aplicadas*, 6(Suplemento 1), 289-296. <https://doi.org/10.62452/8nww1k83>
- Lokier, S. W., & Al Junaibi, M. (2016). The petrographic description of carbonate facies: Are we all speaking the same language? *Sedimentology*, 63(7), 1843-1885. <https://doi.org/10.1111/sed.12293>
- Mancini, M., Weindorf, D. C., Monteiro, M. E. C., De Faria, Á. J. G., Dos Santos Teixeira, A. F., De Lima, W., De Lima, F. R. D., Dijair, T. S. B., Marques, F. D., Ribeiro, D., Silva, S. H. G., Chakraborty, S., & Curi, N. (2020). From sensor data to Munsell color system: Machine learning algorithm applied to tropical soil color classification via NixTM Pro sensor. *Geoderma*, 375, 114471. <https://doi.org/10.1016/j.geoderma.2020.114471>
- Marceau, D. J., Howarth, P. J., Dubois, J. M., & Gratton, D. J. (1990). Evaluation Of The Grey-level Co-occurrence Matrix Method For Land-cover Classification Using Spot Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 28(4), 513-519. <https://doi.org/10.1109/TGRS.1990.572937>
- Marrón, B. S. (2012). Co-occurrence Matrix and fractal dimension for image segmentation. *Revista de Matemática: Teoría y Aplicaciones*, 19(1), 49-63. <https://doi.org/10.15517/rmta.v19i1.2104>
- Martín-Fernández, J. A., Palarea-Albaladejo, J., & Olea, R. A. (2011). Dealing with Zeros. En V. Pawlowsky-Glahn & A. Buccianti (Eds.), *Compositional Data Analysis* (1.a ed., pp. 43-58). Wiley. <https://doi.org/10.1002/9781119976462.ch4>
- Miall, A. D. (1977). Lithofacies types and vertical profile models in braided river deposits: A summary. En *Fluvial Sedimentology* (pp. 579-604). Canadian Society of Petroleum Geologists Bulletin.
- Miall, A. D. (1988). Facies Architecture in Clastic Sedimentary Basins. En K. L. Kleinspehn & C. Paola (Eds.), *New Perspectives in Basin Analysis* (pp. 67-81). Springer New York. [https://doi.org/10.1007/978-1-4612-3788-4\\_4](https://doi.org/10.1007/978-1-4612-3788-4_4)
- Presutti, M. (2004, agosto 11). La Matriz de Co-ocurrencia en la clasificación multiespectral: Tutorial para la enseñanza de medidas texturales en cursos de grado universitario. 4a Jornada de Educação em Sensoriamento Remoto no Âmbito do Mercosul.
- Rollinson, H. R. (1993). Using geochemical data: Evaluation, presentation, interpretation. Longman Scientific & Technical ; Copublished in the U.S. with J. Wiley & Sons.
- Walker, R. G. & Geological Association of Canada (Eds.). (2006). *Facies models: Response to sea level change* (8. print). Geological Association of Canada.

# Predicción de COT a partir de atributos sísmicos, usando algoritmos de Machine Learning en Python

Por **Alejandro Bascur** (Pampa Energía), **Enzo Luna** (Pampa Energía) y **Hernán Merlino** (IGPUBA – FIUBA).

*Este trabajo fue seleccionado en las 3<sup>o</sup> Jornadas de Revolución Digital para Petróleo y Gas.*

El uso de machine learning sobre atributos sísmicos permite predecir el contenido orgánico total (COT) con mayor precisión en formaciones como Vaca Muerta. Esta metodología mejora la caracterización de reservorios no convencionales y amplía la cobertura areal de datos geoquímicos.



**E**l Contenido Orgánico Total (COT), esencial en la evaluación de reservorios no convencionales de shale, proporciona información sobre la cantidad de materia orgánica presente en la roca. El volumen de COT remanente se correlaciona con el volumen posible generado a una madurez dada, es decir, un COT elevado indica mayor capacidad de generación de hidrocarburos durante la maduración térmica, convirtiéndolo en uno de los indicadores para evaluar el potencial de producción en este tipo de reservorios.

El presente trabajo se enfoca en introducir una metodología innovadora, diferente a los enfoques convencionales, con el propósito de mejorar la estimación del COT en la Formación Vaca Muerta, empleando herramientas de ciencia de datos.

A pesar de que la Impedancia P se ha establecido como el atributo principal para la estimación del COT en shale, la inclusión de otros productos sísmicos y la aplicación de esta nueva metodología han permitido reducir los errores por debajo de los niveles alcanzados con métodos de ajuste lineales.

Para este fin, se emplearon datos sísmicos pre-stack y post-stack, así como productos derivados de inversiones sísmicas, en conjunción con mediciones de COT obtenidas directamente de pozos (mediante muestras de cutting y coronas).

La integración de estos conjuntos de datos sísmicos, combinada con técnicas de modelado y análisis de datos utilizando algoritmos de machine learning, ha permitido obtener una representación más completa y detallada de las propiedades de la roca madre y su capacidad de generación de hidrocarburos. Este enfoque ha evidenciado el potencial y la utilidad de la ciencia de datos en la evaluación de reservorios de shale, culminando en una mayor precisión y ajuste, lo que representó un avance significativo en la caracterización, comprensión y precisión de los datos.

## Introducción

La formación Vaca Muerta se destaca como una de las formaciones geológicas más relevantes para la explotación de hidrocarburos no convencionales, tanto el shale oil como el shale gas. En este marco, la geoquímica y la geomecánica juegan un papel fundamental. La integración de estudios geoquímicos y geomecánicos proporciona una comprensión completa de la formación Vaca Muerta.

La integración de datos y modelos de ambas disciplinas optimiza la explotación de los recursos no convencionales presentes en esta formación geológica. Dentro de la amplia gama de estudios ofrecidos por la geomecánica y la geoquímica, se optó en enfocarse en el análisis de la materia orgánica, en particular, el carbono orgánico total (COT).

La medición y comprensión de estos valores se realiza de diversas maneras, como la extracción de coronas y el cutting. Sin embargo, estas mediciones suelen ser puntuales y están limitadas a las ubicaciones de los pozos. Aunque proporcionan un excelente nivel de detalle en la dimensión vertical, su alcance en la dimensión horizontal es limitado.

Aquí es donde la sísmica adquiere relevancia, ya que ofrece una distribución horizontal amplia. No obstante, su resolución vertical suele ser más baja como contrapartida. La adquisición y el análisis de datos sísmicos son vitales para comprender la estructura y composición de los yacimientos. Estos datos ofrecen una perspectiva invaluable para la exploración y producción, pero su análisis e interpretación pueden ser desafiantes debido a la complejidad de las formaciones geológicas y la gran cantidad de información recopilada (varios atributos sísmicos).

En este punto entra en juego el Machine Learning (ML). Los algoritmos avanzados de ML, como las redes neuronales y los modelos de aprendizaje profundo, se presentan como herramientas poderosas para analizar

tanto datos de pozos como datos sísmicos, y realizar predicciones sobre las propiedades de los reservorios.

## Objetivo del proyecto

El objetivo de este estudio es evaluar las herramientas y metodologías de la ciencia de datos aplicadas a datos sísmicos, con el propósito de mejorar la predicción de las propiedades del reservorio. La propiedad seleccionada es el carbono orgánico total (COT), y el objetivo específico es predecir a partir de datos obtenidos en pozos, utilizando la sísmica como medio para la propagación areal.

## Desarrollo

La elección del COT como propiedad de la roca a predecir se justifica por su baja complejidad estructural y el amplio conocimiento disponible sobre esta característica en la Cuenca Neuquina. Además, la disponibilidad de un modelo previo nos permitió utilizarlo como punto de referencia para comparar los resultados obtenidos en este trabajo.

La zona seleccionada corresponde al área El Mangrullo (255 Km<sup>2</sup> aprox.) debido a la calidad destacada de la información sísmica disponible.

El flujo de trabajo desarrollado, detallado en la Figura 1, representa esencialmente un proceso estándar para la construcción de un modelo de Machine Learning (ML), que utilizamos como referencia para nuestro estudio.

## Selección de Datos (Initial Dataset)

En el área de estudio se encontraron 7 pozos con mediciones de COT, de los cuales 6 se obtuvieron mediante cutting y 1 a través de coronas. Además, se recopilaron 35 productos sísmicos (Pre-stack, Post-stack y de inversión) para utilizar como datos de entrada en el modelo. Cada uno de estos productos fue seleccionado por su relación con el parámetro que se busca predecir.

## Métricas de Evaluación

Seleccionar métricas de evaluación antes de construir el modelo es crucial para diseñarlo y optimizarlo eficazmente, asegurando que cumpla con los objetivos del proyecto y las necesidades del negocio. Esto proporciona claridad en los objetivos, facilita la comparación entre modelos, se alinea con los requisitos del negocio y previene sorpresas desagradables en el futuro. Las métricas que nosotros seleccionamos son:

### Error absoluto medio (MAE)

Es una medida del tamaño medio de los errores en una colección de predicciones, sin tener en cuenta su dirección. Se mide como la diferencia absoluta promedio entre los valores predichos vs los valores reales y se utiliza para evaluar la efectividad de un modelo de regresión.

$$MAE = (1/n) \sum_{i=1}^n |y_i - \hat{y}_i|$$

n = número de observaciones en el conjunto de datos.  
y<sub>i</sub> = valor verdadero.  
 $\hat{y}_i$  = valor previsto.

### R<sup>2</sup> (R cuadrado)

Muestra qué tan bien un modelo de regresión (variable independiente) predice el resultado de los datos observados (variable dependiente). R<sup>2</sup> también se conoce comúnmente como coeficiente de determinación. Es un modelo de bondad de ajuste para análisis de regresión lineal.

$$R^2 = 1 - RSS/TSS$$

RSS = suma de cuadrados de residuos.  
TSS = suma total de cuadrados.

### Adecuación de datos

El preprocesamiento de datos es un paso fundamental antes de aplicar un modelo de machine learning, ya que mejora la calidad, consistencia y relevancia de los datos, reduce el riesgo de sobreajuste y contribuye a un mejor rendimiento general del modelo. Algunos de los pasos más relevantes que realizamos fueron:

- Calidad de los datos: Identificación de valores atípicos (outliers) (Figura 2).
- Consistencia de los datos: Estandarización de escalas y normalización de distribuciones.

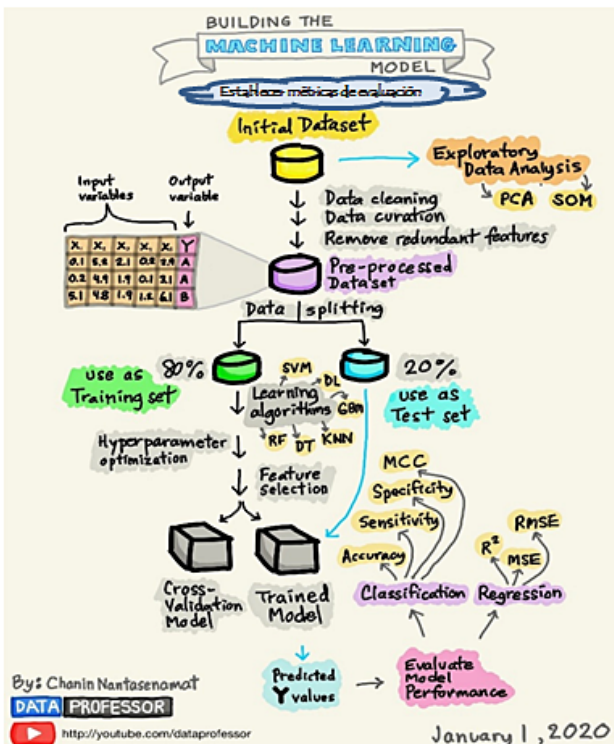


Figura 1. *Cartoon Infographic on building the machine learning model (Draw by Chanin Nantasemanat).*




Figura 2. Outliers.




Figura 3. Oversampling.


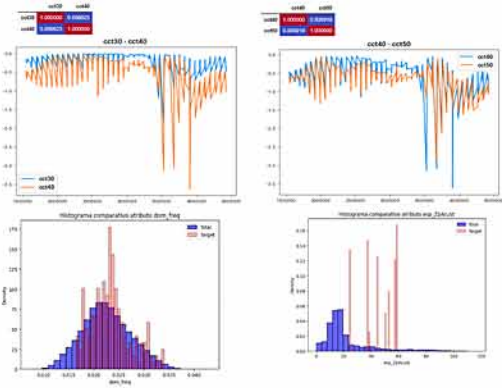


Figura 4. Matriz de Correlación y reducción de Dimensionalidad.



- Balance de Clases: Utilizamos el método ADASYN (Adaptive Synthetic Sampling) para generar muestras sintéticas de forma adaptativa (Figura 3).
- Reducción de Dimensionalidad: Empleamos el análisis de componentes principales (PCA) para la selección de características (Figura 4).
- Prevención de Sobreajuste: Aplicamos técnicas de validación cruzada (k-fold), dividiendo el conjunto de datos en k subconjuntos (“folds”). El modelo se entrena k veces, cada vez utilizando k-1 folds como datos de entrenamiento y el fold restante como datos

de prueba. El rendimiento del modelo se calcula promediando los resultados de las k iteraciones.

### Modelado

Para iniciar el modelado, optamos por utilizar bibliotecas de aprendizaje automático (AutoML). Herramientas como AutoKeras, TPOT y PyCaret están diseñadas para simplificar la construcción, ajuste y evaluación de modelos de machine learning. A continuación, se destacan algunas de las diferencias clave entre ellas:

	AutoKeras	TPOT (Tree-based Pipeline Optimization Tool)	PyCarets
Enfoque	Centrada en la automatización del diseño y la selección de arquitecturas de modelos de deep learning.	Utiliza algoritmos genéticos para explorar automáticamente una amplia gama de posibles pipelines de machine learning y encontrar la mejor combinación de preprocesamiento de datos y algoritmos de modelado.	Diseñada para simplificar el flujo de trabajo de aprendizaje automático desde la preparación de datos hasta la implementación del modelo.
Funcionalidad	interfaz de alto nivel para la creación de modelos de deep learning con pocas líneas de código. Utiliza técnicas como búsqueda bayesiana y la búsqueda aleatoria para la hiperparametrización y armado del modelo.	Búsquedas exhaustivas y automatizadas de pipelines de machine learning, incluyendo preprocesamiento de datos, selección de características y ajuste de hiperparámetros.	Ofrece amplia gama de funciones de aprendizaje automático, como la preparación de datos, la selección y la evaluación de modelos y la interpretación de resultados. Permite la personalización.
Flexibilidad	Orientado a deep learning, gran flexibilidad para ajustar y personalizar modelos de redes neuronales convolucionales, recurrentes y otros tipos de arquitecturas.	Proporciona una variedad de opciones de configuración para controlar el proceso de optimización, incluyendo el número de generaciones, la población inicial y los operadores genéticos.	Interfaz de usuario fácil de usar y una API programática para adaptarse a diferentes niveles de experiencia en aprendizaje automático.

Los resultados obtenidos al comparar los modelos mediante las métricas de evaluación se muestran en la siguiente tabla:

	MAE	R <sup>2</sup>	Modelo Seleccionado
AutoKeras	0.59	0.62	Light Gradient Boosting Machine
TPOT	0.26	0.93	Random Forest Regression
PyCarets	0.98	0.72	Redes neuronales convolucionales

## Resumen

En resumen, al comparar el modelo de referencia con el modelo generado utilizando múltiples datos sísmicos, observamos que este último se ajusta considerablemente mejor, mostrando una dispersión de datos más estrecha (Figura 7). Además, el modelo muestra una buena separación de las distintas zonas.

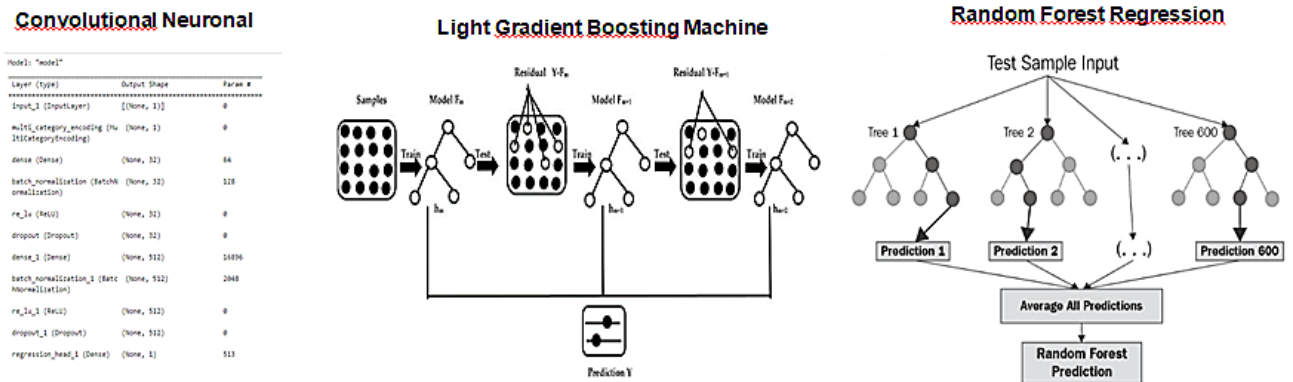


Figura 5. Modelos Candidatos

La Figura 5 muestra el funcionamiento de los distintos modelos seleccionados por cada biblioteca como mejor candidato.

## Comparación de modelos

Al comparar los tres modelos, observamos que tanto el modelo obtenido con PyCaret como el obtenido con TPOT muestran buenos resultados. Sin embargo, optamos por el modelo de TPOT debido a la gran correlación observada entre los valores medidos y los valores predichos, con los puntos muy cerca de la recta de identidad (Figura 6).

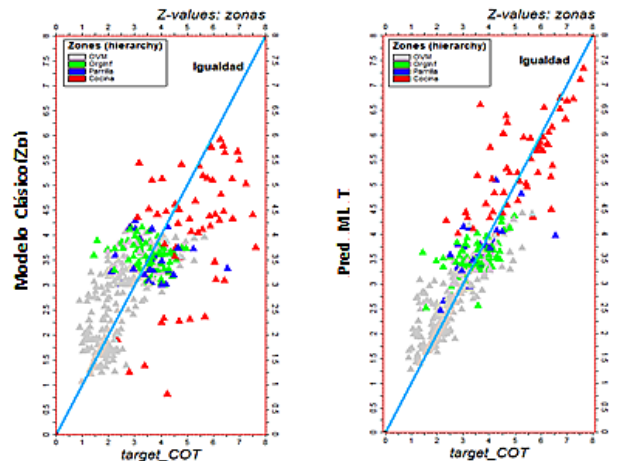


Figura 7. Comparación de modelo de referencia (clásico) vs. modelo de predicción.




Figura 6. Comparación de los 3 modelo de predicción.

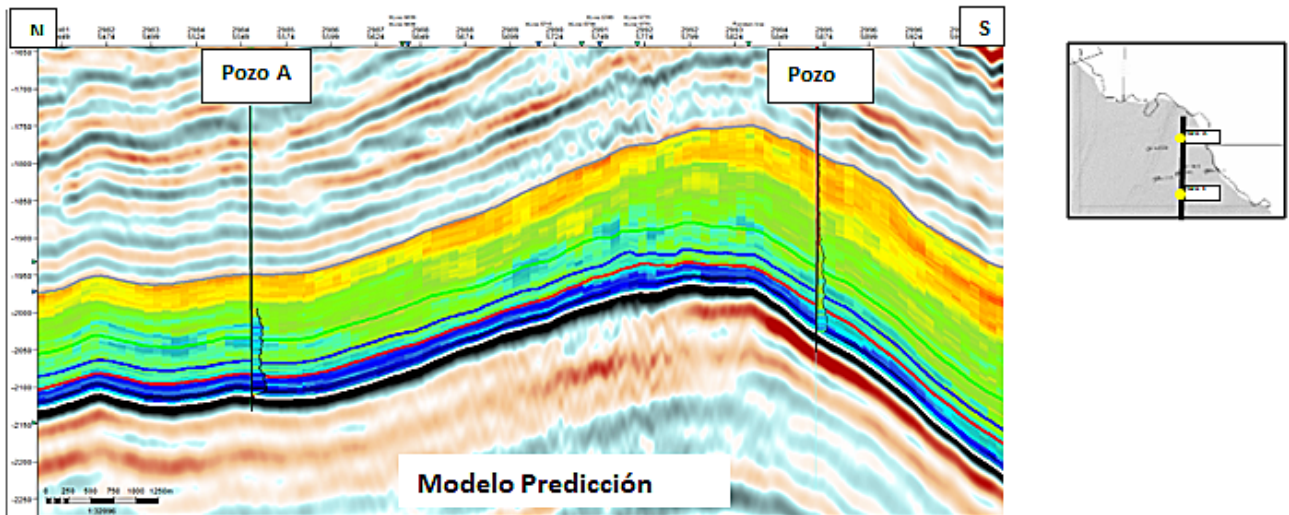


Figura 8. Corte comparando valor de COT en pozo vs. Predicción.




Figura 9. Comparación de puntos medidos vs. Valores predichos.

Este resultado refleja una evaluación altamente satisfactoria de las herramientas y técnicas de ciencia de datos para la estimación del TOC a partir de atributos sísmicos y mediciones de pozo. En la Figura 8 se puede observar la superposición del modelo de predicción obtenido con los datos medidos en pozo, donde se destaca que, a pesar de su baja resolución vertical, el modelo identifica correctamente los rasgos

En la Figura 9 se presenta un corte estratigráfico que compara los resultados de tres modelos por pozo: el modelo de referencia (primero a la izquierda), el modelo ob-

tenido con PyCaret (al centro) y el modelo obtenido con TPOT (a la derecha). Los puntos medidos en el pozo están superpuestos en color rojo. Es notable cómo el modelo generado con TPOT muestra un mejor ajuste a los datos de entrada en comparación con los otros dos modelos.

Otra ventaja importante es que nos proporciona un valioso conocimiento práctico (know-how) que nos permitirá aplicar estas herramientas y técnicas a otros activos y abordar diversas problemáticas con mayor confianza. Como próximo objetivo es aplicar esta metodología a la problemática de la sismoestratigrafía.





# Aplicación de tecnología química surfactante para reducir caudal de inyección de *Gas Lift* en pozos *Shale Oil*

Por *Luciana Masud, María Paz Valderrama* (Vista Energy), *Joanna Villanova y Jimmy López* (PECOM Energía).

**Una prueba piloto con espumante en pozos gas lift del yacimiento Médano de la Mora permitió reducir en un 28% el caudal de gas inyectado. La técnica demostró ser viable para pozos no convencionales con bajo contenido de agua. Menor consumo, mismos niveles de producción.**

**L**a aplicación de productos químicos en la corriente de gas lift es una práctica que se ha vuelto frecuente en los campos petroleros, debido a la combinación de factores operativos como la no disponibilidad de instalaciones apropiadas para una dosificación continua a través de capilares a fondo de pozo, y la necesidad de aseguramiento de flujo o integridad de los activos, dependiendo de cual sea el caso particular.



El gas lift es un método de levantamiento artificial en el que se inyecta gas en el fondo del pozo, para reducir la presión hidrostática de la columna de fluido. El gas de inyección es transportado generalmente a través del espacio anular existente entre la tubería de producción y el casing, e ingresa en el flujo de producción a través de una serie de válvulas insertadas en mandriles, tal como se muestra en la figura 1.

La aplicación de química surfactante o espumantes es habitual en pozos de gas. Facilita el transporte de líquidos hacia la superficie, reduciendo la velocidad crítica de la fase gaseosa. Requiere de la energía del gas producido para facilitar la dispersión de las fases, así como favorecer el espumamiento. Se aplican a través de capilares a fondo de pozo, batcheos puntuales o mediante el uso de barras sólidas aplicadas en la tubería de producción. El sistema capilar implica mayor gasto operativo, y los dos últimos requieren manobras operacionales que dependen de disponibilidad de recursos.

Sarica *et. al* (2015) presentan la viabilidad del uso de espumantes en pozos de petróleo con gas lift, a través de un ensayo experimental sin aplicación en campo. Dicho trabajo valida que la corriente de gas logra la generación de espuma, lo cual

permitió reducir el caudal de gas de inyección como mínimo en un 32%. Martins *et. al* (2019) muestran ya con prueba de campo en ¿un? pozo de petróleo horizontal que los surfactantes pueden ser inyectados a través de capilar o por caudal de inyección de gas sin cambios significativos en su performance.

En este trabajo se presentan los resultados de aplicar espumantes a la corriente de gas lift en superficie aplicado a pozos horizontales de petróleo no convencional. El éxito de la sinergia de la combinación se presenta como porcentaje de reducción de caudal de gas inyectado.

## Ensayo de Laboratorio

Existen métodos normalizados para determinar propiedades de la espuma y evaluar la acción de distintos surfactantes. Básicamente, los métodos consisten en producir el espumamiento de una muestra a la cual se le adiciona una determinada cantidad del agente espumante a evaluar. La espuma puede producirse por medio de la agitación mecánica o bien por soplado de una corriente gaseosa en el seno del líquido (aire, nitrógeno, gas, etc.) a un caudal constante. Este caso de estudio se realizó bajo adaptación de la norma




Figura 1. Instalación de gas lift en fondo de pozo.



Figura 2. Equipo de laboratorio para evaluación de espuma.

ATSM-D892 “Dynamic Test: Método de Columna/Cilindro”.

El producto químico evaluado es un surfactante del tipo no iónico/anfotérico específico para trabajar en relaciones agua/hidrocarburo volumen/volumen (v/v) bajas de hasta 5 por ciento (%) aproximadamente.

La muestra para utilizar debe representar lo más idóneamente posible las condiciones fluidodinámicas actuales del pozo, específicamente el corte de agua, ya que es factor influyente en la degradación de la espuma. Esto debido a que sus moléculas no son polares y su interacción con los surfactantes es completamente diferente.

El ensayo consiste en espumar una muestra objetivo de 200ml en una columna calibrada (Figura 2), mediante el soplado de una corriente de aire a caudal constante aplicando una concentración seleccionada de espumante.

Las variables para monitorear durante el ensayo son:

- I. Formación de espuma cuantificada en segundos para diferentes concentraciones expresadas en parte por millón de volumen (ppmv).
- II. Tiempo de ruptura de espuma cuantificada en segundos a la mayor concentración evaluada.

Condiciones de ensayo:

- Temperatura ambiente
- Muestra de fluido de producción con un 25% v/v agua/hidrocarburo.
- Caudal de aire: 5 Lt/min
- Blanco: Se verifica que la muestra no tiene residual de aminas o fosfonatos que pudiese interferir con los resultados.

Para la primera etapa se dosificaron concentraciones de 2500 y 5000 ppmv, respectivamente. Dichos resultados se presentan en la tabla 1. Los resultados medidos en tiempo de formación de espuma muestran a la segunda dosis como la más eficiente.

Posteriormente, con la dosis más alta se procedió a evaluar el tiempo de ruptura de espuma sin aplicación de ruptores de espuma o anti-

**Tiempo de formación de espuma (segundos)**

	mililitros					
ppmv	0	200	400	600	800	1000
2.500	0	18	35	50	75	90
5.000	0	1	30	48	60	73

Tabla 1. Evaluación de formación de espuma.

**Tiempo de ruptura de espuma (Segundos)**

	mililitros					
ppmv	1000	800	600	400	200	0
5.000	0	30	45	65	85	120

Tabla 2. Colapso de espuma.



Figura 3. Centrifugación muestra dosificada con espumante.

espumantes tal como se muestra en la tabla 2. Idóneamente el tiempo de colapso se debe ubicar entre 60 y 240 segundos, lo cual representa una espuma suficientemente estable pero sin generar inconvenientes en equipos de separación. Es importante mencionar que cada caso es particular y debe definirse mediante ensayos en campo en función de variables operativas.

Adicionalmente, se evalúa en laboratorio a través de la norma ASTM D-96 “Determinación de agua y sedimento por centrifugación” si las muestras dosificadas con espumante generan emulsión. Los resultados presentados en la Figura 3 muestran que la dosificación de espumante no genera inconvenientes de emulsión.

## Ensayos de campo

Puntos por evaluar en el piloto:

- Efectividad del espumante en la reducción del caudal de inyec-




Gráfico 1. Producción de petróleo previo a ensayo en campo.

ción de gas en el sistema gas lift continuo.

- Evaluar si la reducción de gas es equivalente a la que se logra con la conversión de gas lift continuo a intermitente.
- Mantener la producción de petróleo.

El pozo seleccionado es del tipo horizontal con un diámetro de tubería de producción de 2-3/8", una longitud de pozo de 5686 m y una profundidad vertical verdadera de

2904m. La instalación de fondo cuenta con 8 mandriles con válvulas de inyección de gas, y una profundidad máxima de punto operativo de inyección en 2801m, la producción previa al periodo de ensayo se detalla en el gráfico 1 donde el periodo con accionamiento de gas lift se ubica posterior al mes de agosto en el 2020.

El espumante es inyectado directamente en superficie en la corriente de gas lift, y entra en el flujo de gas/líquido dentro de los pozos a través de los mandriles.

Condiciones del ensayo:

- Periodo aproximado: 45 días.
- Presión en boca de pozo inicial: 12 kg/cm<sup>2</sup>.
- Producción de petróleo: 20m<sup>3</sup>/d.
- Pozo con tratamiento químico inhibidor de parafinas en fondo de pozo a través de capilar en 1200m.

Variables por monitorear:

- Caudal de dosificación de espumante.
- Presencia de espuma en muestras en superficie.
- Caudales de producción, Líquido y Gas.
- Presión en boca de pozo.
- Caudal de inyección de gas lift.
- 
- Equipo requerido:
- Equipo dosificador de 1000 Litros.

El ensayo se inicia con una dosis de 150 litros por día, equivalente a 5000ppmv, y paulatinamente se optimiza a 50 litros por día, 2500ppmv en función del caudal de líquido aportado.




Figura 3. Petróleo, presión de boca de pozo, caudal inyectado y dosis de espumante durante piloto Tratar de aumentar tamaño de letra de las leyendas.

Consideraciones:

- La producción del pozo ingresa a separadores bifásicos en una TPF (Temporary Production Facility), haciendo crítica la correcta ruptura de espuma.
- Los pozos No Convencionales con gas lift, requieren inyección de inhibidor de parafinas en fondo de pozo a través de capilar. Es necesario asegurar la compatibilidad entre los productos químicos aplicados, para garantizar que no se generen emulsiones en el sistema.

## Resultados

En la figura 3 se observan las variables monitoreadas de producción, la primera etapa con una dosis de 150l/d, y posteriormente con optimización de dosis. Comparando el inicio y final del ensayo, en general la producción de petróleo y la presión se mantuvieron estables. Se registra una disminución en la curva de petróleo en la etapa de optimización de dosificación de espumante.

Con la dosis de 150litros/día, se redujo el caudal de gas inyectado en un 28% pasando de 18Mm<sup>3</sup>/d a 13Mm<sup>3</sup>/d sin pérdida de petróleo. En cambio, con la optimización de 150 a 50 litros/día, se observa una merma de petróleo de hasta un 16%. El pico de producción inicial son post cierres operativos de pozo. El último caso de análisis es con dosis de 150litros/día y el caudal de inyección inicial. No se optimiza el caudal de inyección, pero se observa un incremento de petróleo de hasta 13%.

Una consecuencia no deseada de una dosis elevada de espumante consiste en la estabilización de emulsiones o afectación del desempeño de los separadores, implicando costos operativos asociados. El control de espuma en superficie mediante el uso de una probeta (Figura 4) y un cronómetro es una variable de rutina de seguimiento en tratamientos espumantes. No se observaron formación de emulsiones en el sistema.



Figura 4. Control de espuma en superficie.

## Conclusiones

- Se valida como ventaja operativa la técnica de aplicación de espumantes a través de corrientes de gas lift, ya que no implica la intervención de pozo para bajada de capilar, o necesidad de recursos adicionales para aplicación de bacheos o barras.
- El uso combinado de espumante en una dosis de 5000ppmv más gas lift, permitió la reducción en un 28% del caudal de gas inyectado durante el periodo ensayado. Valor coherente con la bibliografía en el tema.
- El uso combinado de espumante en una dosis de 2500ppmv más gas lift, permitió la reducción en un del caudal de gas inyectado, pero con una merma asociada de producción del 16%.
- Finalmente, la sinergia de un caudal inyectado optimizado sin

espumante, más la adición de espumante, generó un incremento de producción de hasta el 13%.

- Se desestima la aplicación de espumantes únicamente para pozos productores de gas, ya que al aplicarse en combinación con el gas de inyección en pozos de petróleo, se logra reducir el caudal de gas necesario para transportar a superficie un mismo volumen de líquido.

## Referencias

- Sarica, Yuan, Shang, Pereyra, Kouba, 2015, "Feasibility and Evaluation of Surfactants and Gas Lift in Combination as a Severe-Slugging-Suppression Method", Paper SPE-170595-PA.
- Martins, Marino, Kerem, Guzmán, 2019, "Foam Assisted Gas Lift: The Impact of Different Surfactant Delivery Methods on Oil Well Performance", Paper SPE-195462-MS.
- Bernadiner, 1991, "Foamed Gas Lift", paper was prepared for presentation at the Production Operations Symposium held in Oklahoma City, Oklahoma, April 7-9, 1991.
- Lehrer, Chakraborty, Kuzniarek, 2019, "Application of black oil foamers for slugging mitigation and production enhancement of oil & gas wells", paper presented at the 14th Offshore Mediterranean Conference and Exhibition in Ravenna, Italy, March 27-29, 2019.
- PECOM Energía S.A, s.f, "Sistema de capilar en pozos PQB".

iAPG

# A AOG

XV ARGENTINA OIL&GAS  
EXPO 2025

Exposición Internacional del Petróleo y del Gas

**8 – 11.9.2025**

La Rural Predio Ferial  
Buenos Aires, Argentina

[www.aogexpo.com.ar](http://www.aogexpo.com.ar)

Organiza:



INSTITUTO ARGENTINO  
DEL PETRÓLEO Y DEL GAS

Realiza:



messe frankfurt



# Análisis de contenido de video (VCA) o video inteligente en la industria del petróleo y el gas

## Seguridad en el Trabajo, Protección y Medio Ambiente

El análisis de contenido de video permite identificar riesgos en tiempo real y optimizar la gestión de seguridad, salud y ambiente en la industria del petróleo y gas. Mediante técnicas de machine learning, detecta eventos críticos, evita falsas alarmas y mejora la toma de decisiones. Una solución inteligente para operaciones más seguras y eficientes.

Por **Julio Shiratori** (Consultor de Nuevas Tecnologías en Petróleo y Gas), **Fabio David Chiarandini** (Asset Manager Consultant), **Sebastián Rasilla** y **Diego Estrella** (Arkania Systems).

**E**l Análisis Visual Cognitivo, como parte de los elementos de lo que comúnmente se conoce como Video Analytics, se refiere al proceso de utilizar tecnologías de Inteligencia Artificial, Visión de Máquina (Machine Vision) y algoritmos de segmentación semántica, para examinar y extraer información valiosa a partir de vídeos e imágenes aisladas. Esta tecnología permite analizar automáticamente el contenido visual y extraer datos relevantes de manera eficiente.

En la actualidad este tipo de tecnología ha sido finalmente industrializada e implementada bajo el concepto de herramientas de productividad NO-CODE y no exige conocimientos profundos de la materia para su utilización o aprovechamiento.

El Análisis Visual Cognitivo tiene diversas aplicaciones en diferentes sectores. En el ámbito de la seguridad, se utiliza para detectar actividades sospechosas, realizar un seguimiento de personas o vehículos, o identificar objetos abandonados. También se utiliza en la gestión de multitudes, donde puede contar personas y proporcionar información sobre la densidad de las mismas en áreas específicas.

Otra aplicación común es el reconocimiento facial, que utiliza el análisis de video para identificar y reconocer rostros humanos en imágenes en movimiento. Esta tecnología es utilizada en sistemas de seguridad para identificar personas comparando sus rostros capturados contra bases de datos de personas conocidas o buscadas, pudiendo analizar las expresiones faciales y determinar distintas emociones, lo que puede ser

útil en investigaciones de mercado, estudios de comportamiento o en el campo de la psicología.

En el ámbito del tráfico, nos permite monitorear y analizar el flujo de tráfico en carreteras o intersecciones, identificando patrones de congestión, tiempos de espera y violaciones de tráfico. Estos datos son valiosos para optimizar la gestión del tráfico y mejorar la seguridad vial.

Este tipo de soluciones requiere un procesamiento computacional avanzado y grandes cantidades de datos. Sin embargo, ofrece beneficios significativos al automatizar la extracción de información valiosa a partir de vídeos, lo que ahorra tiempo y recursos en comparación con el análisis manual.

Es importante tener en cuenta las consideraciones éticas y legales al utilizar tecnologías de análisis de video, especialmente en lo que respecta a la privacidad y la protección de datos personales. El cumplimiento de las regulaciones y leyes pertinentes es fundamental en su implementación.

Como introducción podemos decir que el **Análisis Visual Cognitivo robusto es una tecnología poderosa que permite extraer información contextual valiosa. Su aplicación abarca una amplia gama de sectores, desde la seguridad, detección de derrames e indicadores de salud ocupacional hasta la gestión del tráfico, y ofrece ventajas significativas al automatizar el análisis de contenido visual.**

## Desarrollo

El desarrollo del Análisis Visual Cognitivo ha sido posible gracias al

gran avance tecnológico en materia de inteligencia artificial, Procesamiento digital de Imágenes, avanzados algoritmos de Segmentación Semántica de la información y Emulación del lenguaje natural y Evolución historia significativa de procesamiento computacional (Hardware). A través de algoritmos sofisticados, esta tecnología es capaz de procesar grandes cantidades de datos visuales y extraer información relevante de manera automatizada.

Esta capacidad técnica puede ser interpretada de forma modular o granular de la siguiente manera:

- Segmentación del escenario.
- Detección de objetos, formas o figuras.
- Presencia y permanencia.
- Detección de movimiento, trayectorias, velocidad.
- Obtención de información crítica y contextual en escenarios complejos de observación, es decir: análisis, reconocimiento y descripción de comportamiento o de situaciones críticas o peligrosas.

La información visual es sometida a un análisis robusto que podemos describir en una serie de etapas conocidas como:

- **Preprocesamiento: Donde por lo general se combina con tecnologías de mejora de video, como eliminación de ruido, estabilización de imagen, enmascaramiento de nitidez y superresolución, etc.**
- **Segmentación: Detección y filtrado cíclico de elementos conocidos dentro de un escenario, construcción de modelo de datos estadísticos que refuerzan análisis posteriores.**





- **Extracción de características: Descubrimiento**, obtención y recolección automática de características visuales, espaciales y temporales predominantes.
- **Detección: Detección** de características generalizadas de los objetos, formas/figuras basado en Redes Neuronales sintéticas.
- **Reconocimiento: Comparación** exhaustiva de detecciones y características intrínsecas/particulares de ciertos objetos.

En primer lugar, el análisis visual cognitivo, se basa en la detección y seguimiento de objetos estáticos o en movimiento dentro de un escenario. Mediante la comparación constante de características extraídas en cada fotograma, se identifican objetos de interés, como personas, vehículos u otros: como pueden ser la ausencia o presencia de personal, maquinaria o elementos de seguridad o elementos peligrosos, etc.

Una vez que se han realizado las detecciones necesarias, se aplican algoritmos de seguimiento para rastrear su movimiento a lo largo del video. Esto permite obtener información espacial y temporal sobre la trayectoria, velocidad y comportamiento de los objetos en movimiento.

Durante este análisis temporal se utilizan técnicas de Reconocimiento

para identificar características específicas, inferir comportamientos realizando contrastes históricos, que puedan desplazar gravemente indicadores de seguridad normales preestablecidos por la organización.

### Incorporación de VCA en una organización – Pasos a seguir

La incorporación de Analítica de Video en una organización, para mejorar el desempeño en seguridad, medio ambiente y salud ocupacional en empresas de petróleo y gas, requiere la contratación de una compañía especializada en soluciones de inteligencia artificial (IA) y de esta forma permitir a los especialistas en soluciones de IA implementar los algoritmos de IA en requerimientos determinados por las operadoras. Con lo cual, la pregunta inmediata es:

¿Cuáles son los pasos necesarios para la aplicación de Analítica de Video dentro de una organización?

#### Paso 1:

Conectar las cámaras existentes o instalar cámaras específicas en los lugares determinados.

#### Paso 2

Seleccionar las variables a detectar relacionadas con Seguridad, medio ambiente, salud ocupacional y/o

optimización indicadores de rendimiento.

#### Paso 3

Conectar el Sistema con la aplicación de IA para recibir alertas en tiempo real en los tableros de control.

### Algunas soluciones tecnológicas

#### Control de Ingreso/Egreso por Reconocimiento Facial.

Control de asistencia del personal, prohibir o autorizar el ingreso a zonas establecidas, esto nos permite conocer el sector donde se encuentra el operario en todo momento.

#### Flujo de personas y Mapas de calor

El conteo y seguimiento de personas nos permite conocer y regular la ocupación máxima de un lugar en tiempo real, generando alertas cuando la misma es excedida, determinar las zonas más transitadas, o con mayor riesgo de accidentes históricos. Esta herramienta es totalmente customizable para ajustarse a los requerimientos propios de cada espacio y usuario.

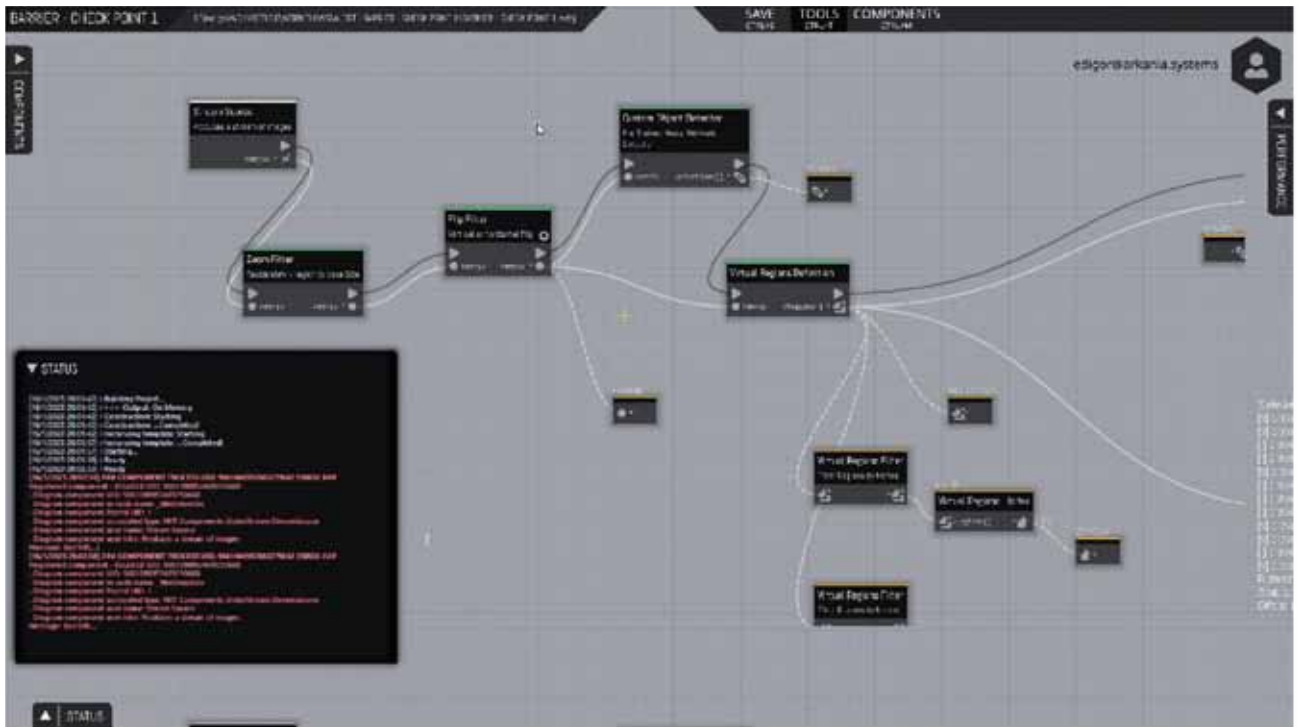
Podemos determinar el flujo de personas en base a distintos patrones obtenidos, y determinar mediante



1-Conectar cámaras existentes o nuevas

2-Detectar comportamientos seleccionados

3-Obtener alertas de variables seleccionadas en tiempo real en tableros de control



los mismos su comportamiento, en contraste con otra información persistente como, horarios y continuidad laboral, estadística de enfermedades y lesiones, clima, etc.

### Detección EPP (Elementos de protección personal)

Controlar el uso de los EPP en cualquier puesto de trabajo o área definida, en la cual se requiera su uso, permitiendo alertar sobre el no uso de los mismos y prevenir accidentes laborales.

### Detección de personas o extremidades en zonas de riesgo.

Crear, controlar, y administrar zonas de riesgo en estaciones de trabajo donde se utiliza maquinaria peligrosa, de esta manera podemos alertar cuando la seguridad del operario se encuentre en riesgo.

### Estimación de pose y ergonomía incorrecta o no saludable según normas EAWS.

Monitoreamos la mecánica de

los movimientos corporales identificando posturas perjudiciales para la salud de los operarios pudiendo de esta manera evitar futuras lesiones o secuelas.

### Detección de hombre caído.

Identificar accidentes laborales en donde una persona se encuentre en el piso pudiendo así priorizar la seguridad del operador, y actuar de manera rápida y eficaz en caso de un siniestro.

### Extracción de información contextual relevante

Analizar la iluminación y las condiciones ambientales en un video, lo que puede ser útil para el seguimiento de objetos en diferentes condiciones de luz e identificar áreas con y sin iluminación.

### Herramientas de productividad Implementación de casos de uso

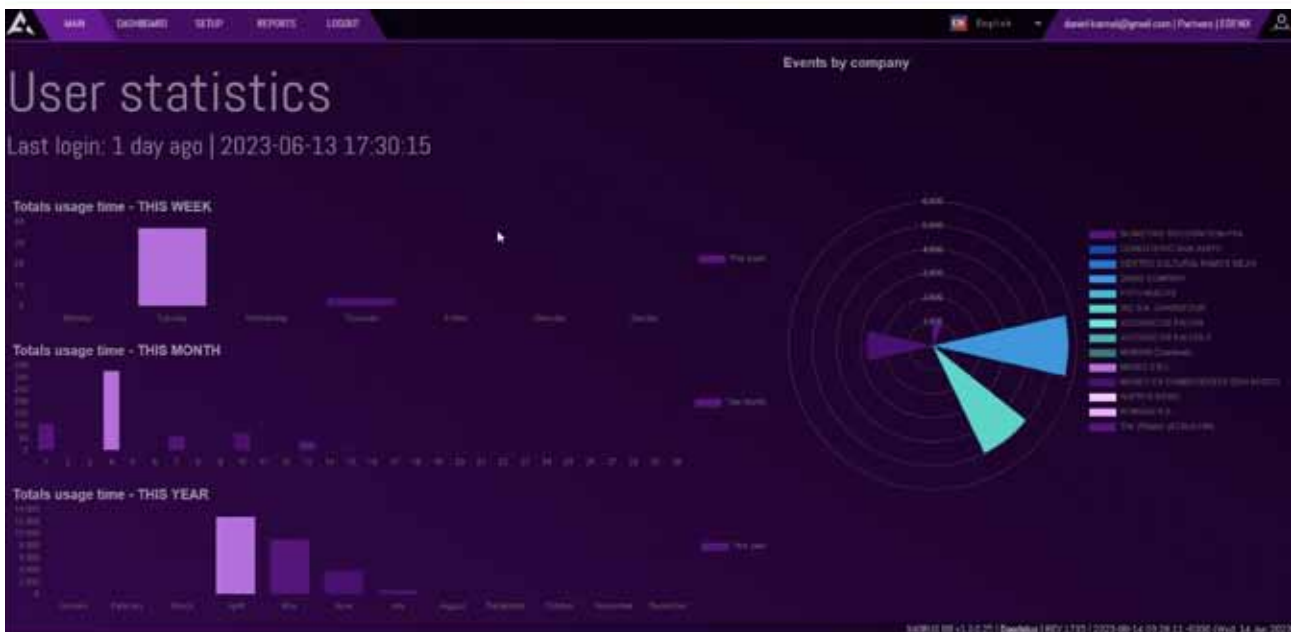

Como se mencionó anteriormen-

te estas tecnologías han sido debidamente encapsuladas e integradas como modelos de componentes que nos permiten hacer uso de las mismas sin necesidad de incorporar grandes departamentos de investigación y desarrollo tecnológico. Siendo su aplicabilidad de manera sencilla similar a la utilización de un sistema CAD (Computer Assisted Design).

Como por ejemplo la siguiente Herramienta:

La herramienta de construcción gráfica y NO-CODE de casos de uso de análisis visual cognitivo consta de un modelo completo y extensible de componentes de alto nivel de abstracción que proporciona reutilización de proyectos basada en patrones de diseño específicos, unificación y abstracción de funcionalidad y estandarización de entradas y salidas.

Dicha herramienta nos permite alcanzar un alto nivel de productividad en la implementación, integración y despliegue de soluciones de código en función de patrones de diseño específicos. Con este Framework logramos una verdadera



productividad en el desarrollo módulos de detección y reconocimiento de los patrones mencionados:

La herramienta facilita el uso de todas las capas, embebe sus funcionalidades en grandes bloques llamados componentes. Permitiendo diseñar visualmente un diagrama o workflow y utilizar estos componentes, conectados de forma inteligente por medio de entradas y salidas estandarizadas, donde participan activamente haciendo su trabajo y suministrando datos y/o resultados a otros componentes, lo que permite al desarrollador o experto en el

análisis del problema o caso de uso enfocarse en encontrar una solución al problema ocultando las complejidades técnicas de fondo

### Monitoreo, control y gestión de eventos

Plataforma de data Analytics que recopila y analiza grandes volúmenes de datos o metadatos extraídos por La herramienta mencionada o alguna aplicación de terceros, detectar patrones de comportamiento estadísticos, analizar índices o determinar tendencias generando even-

tos y alertas.

Esta plataforma de datos ayudará a los expertos a tomar decisiones a través de informes y gráficos obteniendo la información más detallada y amigable.

### Aplicaciones actuales – Experiencia actual y resultados

A continuación, expondremos un ejemplo de aplicación general en otras industrias.

En este ejemplo veremos el uso del VCA en la inspección visual automática en túneles ferroviarios. Es-




de roturas en cableados. Con cámaras térmicas se detectaron áreas calientes, humedad, oxidación y fisuras.

Otra aplicación que ayuda a inspeccionar las áreas de interés es el uso de un vehículo autónomo con controles manuales usado para contingencias. Con el objetivo de:

- 1- detectar situaciones anormales
- 2- inspeccionar la integridad del túnel, las vías y otras infraestructuras con el objeto.

El análisis puede ser realizado en tiempo real o mediante el análisis



tas inspecciones detectaron fallas, roturas, deterioro de instalaciones eléctricas en cableados e identificación de riesgos por corrosión.

The Land Transport Authority of Singapore (hereinafter referred to as "the Authority") invites Proposals for RFI-UAS – THE USE OF AUTOMATION AND ARTIFICIAL INTELLIGENCE IN VISUAL INSPECTION OF TUNNELS IN RAIL AND ROAD MAINTENANCE as advertised in the website at <http://www.gebiz.gov.sg> on 1 March 2017.

Testeos conceptuales satisfactorios fueron llevados a cabo con altos niveles de precisión en la detección



de video luego de una inspección con cámaras. Se decide en función de cada caso. En caso de hacerse en tiempo real y se encuentra un posible deterioro o una anomalía se puede analizar con mayor detalle el tramo deseado.

**Potenciales aplicaciones en la industria energética focalizadas en HSE, eficiencia de la Producción y logística**

El siguiente listado provee ejemplos de aplicación en la industria de energía focalizadas en HSE, eficiencia de la producción y logística. Es



Corrosion of clips



Wet spot on trackbed



muy importante mencionar que quizás estos ejemplos ya han podido ser resueltos por los operadores, sin embargo, la intención de mostrar una serie de ejemplos de aplicación, pueden ayudar a buscar otras soluciones no identificadas en la lista que sigue.

### Seguridad

- Admisión por Reconocimiento Facial y de tarjetas.
- Región de Interés Virtual y Valla de Delimitación.
- Detección de fuego y animales.
- Análisis de video en delitos, vandalismo y sabotaje.
- Monitoreo de condiciones de equipos de perforación y terminación.
- Intrusión de Perímetro.

### Salud ocupacional

- Uso de EPI (Equipo Protección Individual).
- Seguridad en oficinas en sustitución del programa BBS (Seguridad Basada en el Comportamiento).
- Alertas de peligros de ergometría.

### Ambiental

- Detección de fugas onshore/offshore en instalaciones y oleoductos.
- Uso de drones en tiempo real.

### Eficiencia de producción y logística

- Parada de pozos y variaciones térmicas en tuberías.
- Supervisión de eficiencia en máquinas.
- Almacenes inteligentes, mejora en manejo de inventarios
- Incorporación de infraestructura de base de datos actual que permite el acceso de los datos al centro de soporte de decisiones para mejorar el rendimiento.
- Detección de interruptores eléctricos de media tensión abiertos que permitan reducir la puesta en servicio de la red eléctrica lo más rápido posible.

### Ejemplo de la lista relacionado con Monitoreo de condiciones de equipos de perforación y terminación.1(SPE-213764-MS)

El monitoreo de las condiciones del equipo de perforación y terminación utilizando análisis de video es una práctica cada vez más común en la industria petrolera.

En el contexto de la perforación y terminación de pozos, el monitoreo con videoanalítica puede proporcionar numerosos beneficios. Algunas aplicaciones clave incluyen:

1. Seguridad: El análisis de video puede detectar automáticamente situaciones peligrosas en el equipo de perforación y termi-

nación, como fugas de productos químicos, incendios o comportamientos inseguros por parte del personal. Esto permite una respuesta rápida y eficiente para prevenir accidentes y garantizar la seguridad de los trabajadores.

2. Mantenimiento predictivo: Mediante el análisis de video, se pueden identificar señales de desgaste o fallas en los equipos antes de que ocurran problemas importantes. Por ejemplo, al monitorear la vibración, el calor o los patrones de movimiento de las partes del equipo, se pueden detectar anomalías que indiquen la necesidad de mantenimiento o reparación.

3. Eficiencia operativa: La videoanalítica puede ayudar a optimizar las operaciones de perforación y terminación al proporcionar datos en tiempo real sobre el rendimiento del equipo y los procesos. Por ejemplo, se pueden detectar cuellos de botella en la cadena de producción, identificar áreas de mejora en los procedimientos o medir la productividad de la maquinaria.

4. Control de calidad: El análisis de video puede utilizarse para inspeccionar visualmente el equipo y los productos terminados, asegurando que cumplan con los estándares de calidad requere-

ridos. Esto es especialmente relevante en la terminación de pozos, donde es crucial garantizar la integridad de los sistemas de sellado y las conexiones

Además podemos considerar ventajas adicionales

1. Control de acceso a locación
2. Cumplimiento de personal con:
  - zonas de exclusión (zonas no permitidas al tránsito de personas)

- usos de elementos de protección (casco, guantes, anteojos de seguridad, etc.)
3. Detección temprana de derrames y pérdidas
  4. Mediciones de casing, tubings y cañerías de perforación
  5. Detectar eventos de revisión en cada sector del equipo de perforación y somnolencia.
  6. Partnership: sinergia y compromiso



## Conclusiones

El análisis de contenido de video VCA puede implementarse en la industria de energía para mejorar los indicadores de seguridad, medio ambiente, seguridad ocupacional y algunos indicadores de rendimiento.

La mejora de los indicadores objetivos de seguridad y medio ambiente dentro de una compañía operadora están asociados a la temprana identificación de comportamientos no deseados y a la temprana identificación de derrames.

Una vez que la compañía operadora detecta la necesidad de cualquier aplicación, los pasos a seguir para su implementación consisten en utilizar una cámara existente o instalar una cámara específica, que detecta mediante un algoritmo de IA los comportamientos determinados para luego mostrarlos en un tablero en un formato que sea comprensible tanto para desarrolladores de software como para operadoras del sector.

Las potenciales aplicaciones mostradas en empresas de energía son a título de ejemplo para que el lector pueda visualizarlas.

Consideramos que es primordial que las empresas operadoras, en función de sus compromisos y/o objetivos en HSE, visualicen su potencial aplicación considerando todas las soluciones descriptas.

Es en ese momento cuando la compañía dedicada a VCA puede insertarse para que en conjunto con la empresa operadora puedan implementar la solución deseada.

## Bibliografía

1. SPE-213764-MS. Methodology to Evaluate Video Analytics for Drilling Safety Operation using Machine Learning .Paper presented at the Middle East Oil, Gas and Geosciences Show, Manama, Bahrain, February 2023.



# Congresos y jornadas

Te adelantamos los eventos ya confirmados para el año 2025. Además, seguimos ofreciendo cursos *online* para que puedas tomar en cualquier momento del año.

## Cursos *online*

**Curso Básico: La industria de E&P de Petróleo y Gas Natural**  
Instructor: *Rubén Caligari*

**Herramientas de Proyecto: WBS - Administración de alcance**  
Instructores: *Nicolás Polverini* y *Fabián Akselrad*

**Registro de Pozos I y II**  
Instructor: *Alberto Khatchikian*

## 2025

**AMPP - Cathodic Protection Tester (CP1)**  
Del 05 al 09 de mayo  
Instructores: *Héctor Albaya*, *Norberto Pesce*

**AMPP - Cathodic Protection Technician (CP2)**  
Del 12 al 16 de mayo  
Instructores: *Héctor Albaya* y *Norberto Pesce*

## Congresos

**5to Congreso Latinoamericano de Perforación y Terminación**  
Del 28 al 30 de octubre  
Universidad Católica Argentina - Ciudad de Buenos Aires

**7mo Congreso Latinoamericano y del Caribe de Refinación**  
Del 9 al 11 de septiembre  
En La Rural, Predio Ferial de Buenos Aires

**Argentina Oil & Gas**  
Del 9 al 11 de septiembre  
En La Rural, Predio Ferial de Buenos Aires

**Seguinos en nuestras redes**



**INSTITUTO ARGENTINO  
DEL PETROLEO Y DEL GAS**

**[www.iapg.org.ar](http://www.iapg.org.ar)**



## NOVEDADES DE LA INDUSTRIA

### Tenaris anuncia la incorporación de un tercer set de fractura hidráulica en Vaca Muerta

*Esta inversión consolida a Tenaris como uno de los actores más relevantes del mercado de servicios para pozos no convencionales. La decisión busca dar respuesta a la demanda creciente de este tipo de operaciones en la Cuenca Neuquina, donde se encuentra la segunda reserva más grande de gas no convencional y la cuarta de petróleo no convencional del mundo.*

Tenaris anunció la incorporación de un nuevo set de fractura hidráulica en Vaca Muerta, más moderno, eficiente y con una potencia superior a los disponibles del mercado. El proyecto implica una inversión de 110 millones de dólares, continuando el camino para consolidar a la compañía como uno de los actores más relevantes del mercado de servicios para pozos no convencionales. Esta inversión también contempla la incorporación de un nuevo set de coiled tubing, por lo que la compañía pasará a contar con tres sets de fractura hidráulica y tres sets de coiled tubing.

El objetivo es abastecer la demanda creciente de este tipo de operación en la Cuenca Neuquina, donde se encuentra la segunda reserva más grande de gas no convencional y la cuarta de petróleo no convencional del mundo, clave para el desarrollo energético e industrial de la Argentina.

“Para 2026 habremos invertido más de 240 millones de dólares para brindar servicios en proyectos de explotación no convencional desde que tomamos la decisión estratégica de adquirir nuestros primeros sets de fractura hidráulica y coiled tubing en 2020” expresó Javier Martínez Álvarez, presidente de Tenaris para Cono Sur.

Tenaris conjuga know how industrial, de operación y de gestión de servicios, diferencial que ninguna otra compañía puede ofrecer. Desde el comienzo de la operación de esta unidad de negocios, ya superó las 5.000 fracturas y, con el tercer set de fractura hidráulica, Tenaris se posicionará como el tercer proveedor de este servicio más importante del país, reafirmando el compromiso con sus clientes y el crecimiento de Vaca Muerta.

El nuevo set de fractura que estará sumando Tenaris contará con 28 bombas y un total de 70.000 hhp. Además, incorporará la tecnología DGB TIER IV que le permite mejorar su eficiencia (como fuente de energía incorpora el uso de GNC reduciendo el consumo de diésel en un 70%). Este será el primer set en el país con esta tecnología y se espera que esté operativo a principios de 2026.

En paralelo, Tenaris está finalizando la construcción de una nueva base en Vista Alegre, Neuquén, la cual se estima que esté operativa durante el primer semestre del año.

De esta manera, Tenaris busca posicionarse como una de las empresas líderes en eficiencia y calidad de servicio, apoyándose en el soporte técnico de su Centro de Investigación y Desarrollo, las capacidades de su gente, sus equipos y la digitalización de las operaciones.



## El sector químico y petroquímico comenzó el año con resultados mixtos

Las Pymes del sector registraron un leve crecimiento en producción y ventas locales intermensualmente.



El informe mensual, llevado adelante por la Cámara de la Industria Química y Petroquímica (CIQyP®), sobre el panorama sectorial destacó que durante enero de 2025 las exportaciones aumentaron un 10% al respecto del mes anterior. En cuanto a la variación interanual también se observa un aumento importante del 63%, favorecido por los subsectores como básicos orgánicos, finales termoplásticos y agroquímicos. Por su parte, en el acumulado del año se observó una suba.

El Informe de la Cámara resaltó que la producción del sector durante el primer mes del año 2025 decreció un 7% respecto al diciembre 2024, argumentado por paradas de planta estacionales y bajo nivel de producción. Al comparar con el mismo mes del año anterior, se observa que hubo crecimiento del 23%; mientras que el acumulado del año para este mes reflejó valores positivos.

A su vez, el relevamiento de la CIQyP® indicó que las ventas locales disminuyeron, en las tres variables: en la mensual, en la interanual y en el acumulado.

Por su parte, la reseña elaborada por la CIQyP® sobre las PyMIQ (Pequeña y Mediana Industria Química),

señaló que en enero 2025 la producción creció un 2% y las ventas locales un 1%; mientras que las exportaciones se mantuvieron, todo con respecto a diciembre 2024. Con respecto a la variación anual y la acumulada, tanto la producción como las ventas locales cayeron; pero en las mismas variables las exportaciones subieron en ambos casos.

Durante enero de 2025, la balanza comercial medida en dólares, de los productos del sector fue un 32,06% menor al mismo mes del año anterior, con variaciones negativas del 10,18% en las importaciones y del 42,4% en las exportaciones.

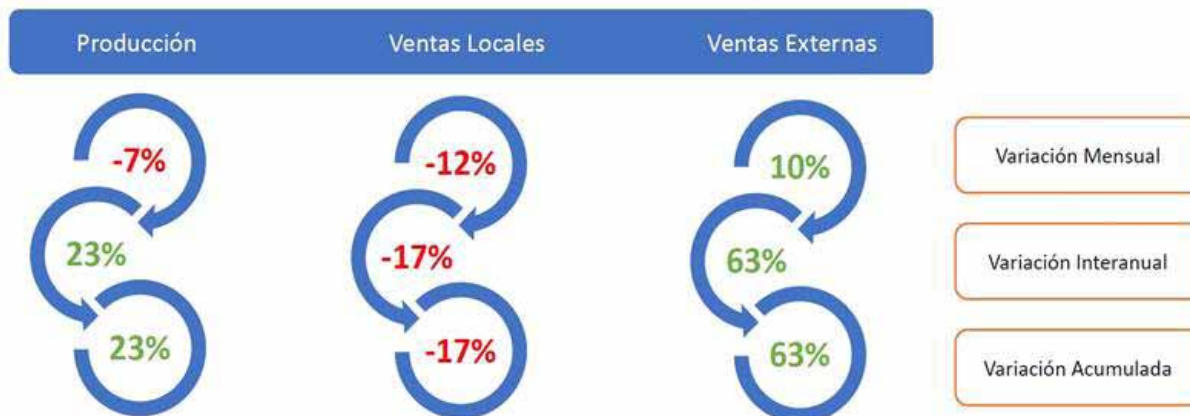
Con respecto a la capacidad instalada de las industrias que contribuyen con información para el informe de la CIQyP®, esta presentó que durante enero de 2025 tuvo un uso promedio del 64% para los productos básicos e intermedios y del 40% para los productos petroquímicos.

En conclusión, las ventas totales del sector en general, que incluye a las PyMIQ, (mercado local + exportaciones) de los productos informados por las empresas participantes del informe, durante enero 2025, fueron de 256 millones de dólares.

“El sector químico y petroquímico sigue la tendencia de la industria en general, con menores ventas locales y con aumento de exportaciones, pero sin embargo los datos de producción aún siguen menores a períodos anteriores. Se vislumbra un crecimiento del producto interno del país en 2025 que seguro impactará en el sector”, enfatizó Jorge de Zavaleta, director ejecutivo de la Cámara de la Industria Química y Petroquímica (CIQyP®).

### Resumen Ejecutivo y Panorama Sectorial

La Cámara de la Industria Química y Petroquímica emite mensualmente, desde 1999, un informe sobre la actividad industrial cuyas fuentes son las empresas del



sector, el Instituto Nacional de Estadística y Censos (INDEC), Penta-Transaction-Estadísticas Import-Export y el Banco Central de la República Argentina (BCRA).

El trabajo cuenta con diferentes niveles de desagregación y se organiza en bloques productivos, los que a continuación se detallan: productos Inorgánicos, petroquímicos básicos, petroquímicos intermedios y finales termoplásticos (polímeros y elastómeros), finales agroquímicos (agroquímicos y fertilizantes); y PyMIQ (Pequeña y Mediana Empresa Química).

## Shell presenta la Nueva Shell Evolux Diesel

*En el marco de su presencia en una nueva edición de ExpoAgro, Raízen Argentina, licenciataria de la marca Shell, presentó la nueva Shell Evolux Diesel con su innovadora fórmula de limpieza triple acción, especialmente formulada para motores de vehículos pesados, como los utilizados en flotas de camiones, transportes de logística, vehículos de reparto y maquinaria agrícola.*



Este combustible diésel grado 2 ayuda a limpiar y proteger los componentes clave del sistema de combustible, como los inyectores, evitando la acumulación de depósitos que pueden reducir el rendimiento. “La tecnología de Shell Evolux Diesel garantiza una mejor recuperación de la potencia, permite lograr la máxima eficiencia del combustible y reduce los costos operativos de los equipos. Pero lo más importante: brinda a nuestros clientes la confianza que necesitan”, comentó Carolina Wood, Directora de Marketing de Raízen.

En respuesta a las demandas de los usuarios, hemos desarrollado esta fórmula para ofrecer mayor eficiencia y protección del motor, mejorando la experiencia de conducción y reduciendo costos operativos. “Para cumplir con los requerimientos de los clientes y lograr la eficiencia buscada, necesitamos mantener limpios los sistemas de inyección. Esto se consigue con la fórmula de limpieza triple acción, que, junto con un combustible de alta calidad, como son históricamente los de Shell, conforman nuestro nuevo producto Shell Evolux Diesel”, agregó Juan Carlos Van Durme, Coordinador del Centro Técnico de Raízen.



## Mauro Avendaño, nuevo socio de Tecnología de KPMG

Con más de 20 años de experiencia en la industria IT, Mauro Avendaño fue incorporado a KPMG Argentina como nuevo socio responsable del servicio de Tecnología que las incluye especialidades Data & AI, Intelligent Automation, Customer Experience, y Cloud. De profesión Ingeniero en Sistemas posee un Máster en Big Data en la Universidad Técnica Nacional (UTN) se define como “una persona apasionada por la tecnología y siempre dispuesta a aceptar los desafíos y propuestas relacionadas al crecimiento profesional. Me enfoco en crear soluciones y dar valor a mis clientes a través de las palancas transformacionales tecnológicas que están evolucionando en el mercado y aportan un gran valor a los negocios”. Posee un amplio recorrido en soluciones tecnológicas en distintos sectores como Telecomunicaciones, Servicios Financieros y Energía, entre otros.

La innovación tecnológica es hoy la principal fuerza motriz que impulsa básicamente una renovación completa del conocimiento con un fuerte impacto en el mundo productivo, los servicios y el mercado laboral. Las empresas vienen identificando la importancia de saber administrar sus datos para mejorar los negocios en un mercado cada vez más competitivo. Son activos estratégicos y clave para volver a las organizaciones más eficientes, sea cual fuere el mercado, industria o sector en el que operan.

“Es importante tener una visión 360 de estas nuevas palancas tecnológicas para darle a nuestro cliente soluciones concretas a sus desafíos. Por eso el foco es ser su socio estratégico para atender sus problemas de hoy y adelantarse a los de mañana”, agrega Avendaño.

## YPF Digital implementará tecnología de Google Cloud para potenciar la App YPF

*Se buscará posicionar la aplicación como la herramienta principal de relacionamiento digital de la compañía de energía del país con sus millones de usuarios.*

YPF Digital (YDI), la sociedad que gestiona y potencia los activos digitales de YPF, firmó un acuerdo estratégico con Google Cloud, área que brinda servicios de nube y que permite a las compañías crecer en la era digital a través de una amplia gama de soluciones de infraestructura, almacenamiento, seguridad, análisis de datos e inteligencia artificial.

YPF Digital apuesta por evolucionar la App YPF, la primera billetera digital de una empresa energética del país, poniendo foco en la innovación y con el objetivo de potenciar la atención y los servicios ofrecidos para sus clientes. Dentro de este acuerdo, una de las tecnologías de Google Cloud será la base para el desarrollo de servicios de Asistentes Virtuales (BOTS), para una atención más eficaz, personalizada incorporando el análisis de datos y mayor seguridad de sus operaciones en la nube.

“Desde su lanzamiento en 2019, la App YPF se ha consolidado como la herramienta más visible de nuestra estrategia de digitalización, ofreciendo a los usuarios una experiencia mejorada en nuestra red de estaciones de servicio. YPF Digital es el vehículo por el cual buscamos acelerar esta transformación, esta alianza potencia esta visión con foco en la experiencia de usuario en la eficiencia operativa y en una cultura de innovación continua en todos nuestros servicios.”, afirmó Guillermo Garat, presidente de YPF Digital.

A los fines de avanzar con este acuerdo Guillermo Garat, presidente de YPF Digital, y Mauro Cercos, Gerente General de YPF Digital, se reunieron con las autoridades de Google Cloud, Eduardo López, Presidente de Google Cloud para América Latina; Fernando Mollón, Head de Argentina, Chile, Colombia, Perú, Uruguay, Centroamérica y el Caribe; Natalia Scaliter, Gerente General de Google Cloud Argentina, Paraguay y Uruguay; y Cristian Ferme, Responsable Comercial de Google Cloud para cuentas estratégicas.

“En Google Cloud, nos entusiasma colaborar con YPF Digital en su camino hacia la transformación de la movilidad en Argentina. Estamos seguros de que podremos llevar sus objetivos de negocio a nuevos horizontes, aprovechando el poder de la nube para crear soluciones más sostenibles, centradas en el cliente y focalizadas en la innovación. Juntos estamos dando un paso importante hacia un futuro más eficiente, transformador y conectado para Argentina”, manifestó Natalia Scaliter, Gerente General de Google Cloud Argentina, Paraguay y Uruguay.

## Pampa Energía se hace fuerte en Rincón de Aranda con 28 pozos perforados

*Desde su ingreso al área en 2023, la compañía perforó a ritmo récord y proyecta plena producción en 2025. En su primer desarrollo de crudo no convencional.*

Pampa Energía avanza a toda velocidad en Rincón de Aranda, su primer proyecto propio de producción de petróleo no convencional. A menos de dos años de iniciar la perforación, la compañía ya puso en marcha 28 pozos y planea completar su desarrollo en 2025, con una capacidad máxima de producción que se sostendrá hasta 2026.

Esteban Falcigno, gerente de Coordinación e Infraestructura de la empresa, estuvo en la disertación de Vaca Muerta Insights 2025 explicó el rápido crecimiento del proyecto.

“Desde agosto de 2023, cuando montamos el primer equipo de perforación, el crecimiento ha sido acelerado. Rápidamente sumamos un segundo equipo y luego incorporamos un ‘spader’, un equipo más pequeño para adelantar la perforación de tramos verticales. A la fecha, ya tenemos 28 pozos iniciados”, detalló.

El ejecutivo subrayó que este desarrollo representa un salto para la compañía, ya que es su primera incursión en la producción de crudo shale. La estrategia inicial incluyó la perforación de siete pads de cuatro pozos cada uno, con la exploración de dos horizontes distintos, con ramas horizontales de 2.500 metros.

### Pampa Energía: un yacimiento donde hay todo por hacer

La operadora, más allá de los objetivos de producción, tiene todo por hacer en ese yacimiento, más allá de haberse nutrido de información geológica del área. Pampa Energía tuvo que construir de cero la infraestructura del área, que se encontraba prácticamente intacta antes de su llegada.





“Tuvimos que diseñar las instalaciones rápidamente y montar una planta temporal de tratamiento de crudo con una capacidad inicial de 20.000 barriles diarios”, señaló Falcigno.

La decisión de avanzar con la inversión se sustentó en datos previos. Antes de obtener la concesión, Pampa perforó dos pozos exploratorios en la zona, lo que permitió evaluar caudales y productividad. El resultado positivo de la exploración, y la buena producción inicial de los pozos, le permitió seguir avanzando en el proyecto.

“Nos beneficiamos de los desarrollos previos de otros operadores en la zona. Eso nos dio confianza para encarar el proyecto con una estrategia clara y eficiente”, agregó el directivo.

Los primeros pozos estarán conectados a producción en los próximos días, según detalló el ejecutivo de Pampa Energía. El objetivo para 2025 es completar los siete pads y alcanzar la capacidad máxima prevista.

De esta manera, también la compañía busca consoli-

dar su presencia en el segmento del petróleo no convencional con una operación de alto rendimiento.

#### **Rincón de Aranda, otra promesa cerca de Añelo**

El desarrollo de Rincón de Aranda es una página nueva en el desarrollo de Pampa Energía, y se suma a los jugadores del shale en la Cuenca Neuquina.

Pampa Energía intensificó sus esfuerzos de producción en la provincia de Neuquén. En junio de 2023, la compañía adquirió el 45% restante de participación en este bloque, y alcanzó el 100% de los derechos sobre el área. La adquisición permite a Pampa incrementar tanto sus reservas como su producción de petróleo no convencional.

La empresa tiene prevista una inversión de 700 millones de dólares para 2025 y planea alcanzar los 1.500 millones hasta 2027, con el objetivo de multiplicar por diez su producción de petróleo y llegar a 50.000 barriles por día.

# NOVEDADES DESDE HOUSTON



## Desayuno con el CEO de YPF en el IAPG Houston



En el marco del ciclo de desayunos de encuentro con los protagonistas o CEO Series Breakfast, el IAPG Houston inauguró con éxito la temporada 2025 con la presencia del CEO y presidente de YPF, Ing. Horacio Marín.

En efecto, con un auténtico SOLD OUT de inscripciones y ante unas 300 personas, el líder de la mayor argentina realizó importantes anuncios para el sector, con amplia repercusión.

Su presencia en la ciudad texana coincidió con el evento anual CERA Week, que dio cita a los principales representantes del mundo del sector de la Energía.



# NOVEDADES DEL IAPG



## Nuevos aportes al programa de becas de la Provincia del Neuquén

Un año después de que el Instituto Argentino del Petróleo y del Gas (IAPG) firmara, junto a la máxima autoridad del Gobierno de la Provincia de Neuquén, un acuerdo de cooperación para promover el patrocinio empresarial de las empresas hidrocarburíferas al Plan de Becas Provinciales “Redistribuir Oportunidades - Gregorio Álvarez”, más compañías sumaron fondos a la iniciativa.

En efecto, la empresa Pluspetrol confirmó que un aporte que lo convierte en “aliado platino”. En tanto, el IAPG se convierte en “aliado bronce” en relación a un patrocinio instrumentado por Shell Argentina

La acción se rubricó en un encuentro realizado por

el gobernador Rolando Figueroa junto al gerente general de Pluspetrol, Julián Escuder; y Ernesto López Anadón, presidente del IAPG.

Según el Gobernador Figueroa, estos aportes, al igual que los que realizan otras empresas, permiten dar continuidad a una política educativa diseñada por su gobierno quien comprometió en 2024 al crearse este compromiso, “a inclusión de todos los neuquinos en edad escolar, independientemente de la región, ciudad, pueblo o paraje en el que residen”. Según datos de la gobernación neuquina en 2024 el programa alcanzó a un total de 19.232 becarios de todos los niveles educativos en toda la provincia.

### Un año de actividades

La iniciativa provincial busca promover oportunida-



des de permanencia, egreso y reinserción educativa en todos los niveles y en la formación técnica, profesional y capacitación laboral para “neuquinos de entre 4 y 35 años”.

Esto se concretó en marzo de 2024 cuando el gobernador neuquino y el IAPG suscribieron un acuerdo que apuntó a la promoción de acciones conjuntas “de colaboración y complementación para la realización de actividades destinadas al desarrollo técnico, la excelencia profesional y la divulgación de actividades relacionadas con las áreas vinculadas a la industria de los hidrocarburos”.

Por su parte, el IAPG se comprometió a divulgar entre sus empresas asociadas las características y oportunidades de colaboración que el Plan de Becas ofrece para el desarrollo humano, a través del apoyo a la educación de quienes reciban los Planes; como reaseguro de la sostenibilidad del desarrollo futuro de las actividades de

la industria al potenciar los recursos humanos que serán necesarios en el futuro.

Inicialmente el gobierno provincial había sumado a cuatro empresas patrocinadoras: Gas y Petróleo del Neuquén (GyP), Pan American Energy (PAE), Tecpetrol y Vista Energy.

Desde el Instituto se indicó que el lanzamiento y objetivo de este plan de subvenciones es compatible con los fines de la institución, puesto que “entre los objetivos fundamentales del IAPG se apunta a propender a la formación de personal idóneo para la industria de los hidrocarburos, para colaborar con las instituciones científicas y docentes del país y del extranjero”; así como para “fomentar la cooperación técnica e institucional con organismos públicos y privados, nacionales y extranjeros que tengan objetivos comunes, con los del Instituto”.

El programa se financia con el aporte mixto del Estado provincial y de empresas que operen en Vaca Muerta.

